


# Llicenciatura en Ciències i Tècniques Estadístiques

**Títol: Estimació, selecció i interpretació de models bayesians per avaluar la millora sanitària en projectes col·laboratius**

**Autor: Núria Mora**

**Director: Dr. Marc Sáez**



**Facultat de Matemàtiques  
i Estadística**

UNIVERSITAT POLITÈCNICA DE CATALUNYA



Facultat de Matemàtiques i Estadística  
Universitat Politècnica de Catalunya

Projecte Fi de Carrera

**ESTIMACIÓ, SELECCIÓ I INTERPRETACIÓ  
DE MODELS BAYESIANS PER AVALUAR  
LA MILLORA DE L'ATENCIÓ SANITÀRIA  
EN PROJECTES COL·LABORATIUS**

Núria Mora

Director: Dr. Marc Sáez



## **AGRAÏMENTS**

M'agradaria agrair, principalment, a la Dra Rosa Suñol i el Dr Joaquim Bañeres per haver deixat realitzar el meu Projecte Final de Carrera a partir d'unes dades pertanyents a un projecte de l'Institut Universitari Avedis Donabedian i facilitar tots els recursos necessaris per poder presentar amb èxit aquest treball. Al Dr Pedro Delicado per haver acceptat la ponència a la FME. A tots els meus companys de la FAD per haver seguit i aguantat tot aquest procés amb paciència i humor, donant-me el seu suport en cada moment complicat. A la meva família, per la seva tussoderia. A en Xavi, per animar-me i consolar-me. I no vull acabar sense donar les gràcies, molt i molt especialment, a la Carola Orrego i al Dr Marc Sáez. Ells són els que, realment, han patit i viscut aquest període amb mi. M'han aconsellat, format, ajudat, reclozat, animat,...Si aquest projecte ha estat possible, és gràcies a ells. **MOLTÍSSIMES GRÀCIES!**



# RESUM

**Títol:** Estimació, selecció i interpretació de models bayesians per avaluar la millora de l'atenció sanitària en projectes col·laboratius.

**Contextualització:** Els projectes col·laboratius són una metodologia freqüentment emprada per aconseguir millores en l'àmbit de la seguretat de l'atenció al pacient. Aquest són projectes multicèntrics, i es caracteritzen per la possible existència de múltiples fonts de variabilitat en la millora originada per l'impacte de la intervenció dels centres participants que poden esbiaixar la seva avaluació. Una bona metodologia en l'ajust dels models de regressió utilitzats permetrà obtenir resultats òptims.

**Objectius:** Desenvolupar una metodologia eficaç per identificar el model bayesià que millor s'ajusti a les dades disponibles per a l'avaluació de la millora dels indicadors de qualitat de l'atenció al pacient dels centres sanitaris. Aquesta metodologia consisteix en estimar, seleccionar i interpretar models bayesians.

**Mètodes:** Per a dur a terme la metodologia presentada s'han utilitzat mètodes d'estimació Bayesiana ajustant, gradualment, models de regressió lineal múltiple i generalitzats, amb resposta binomial i poisson, i efectes fixos, aleatoris i mixtes. Tots els anàlisis estadístics s'han realitzat amb el software R, en la seva versió 2.14.0, utilitzant la llibreria creada recentment INLA.

**Resultats:** Sobre dos casos exemple promoguts per l'Aliança de la Seguretat del Pacient i el Departament de Salut entre els anys 2007 i 2009, s'ha posat en pràctica la metodologia esmentada per a l'obtenció de l'estimació de la millora dels indicadors de qualitat referents al projecte col·laboratiu IMPIC-09 i PREVENCIÓ DE CAIGUDES. Per ambdós projectes s'ha seleccionat el millor model que ha permès obtenir els resultats de la millora per cada un dels seus indicadors definits, considerant, únicament, els efectes fixos en el cas del projecte IMPIC-09 i els efectes mixtos (fixes i aleatoris) en el cas del projecte PREVENCIÓ DE CAIGUDES.

**Conclusions:** En aquest treball s'ha pogut validar la **metodologia gradual** que consisteix en ajustar un model inicial d'efectes fixes i anar-hi afegint, jeràrquicament, els efectes aleatoris dels clústers, responsables de les diferents fonts de variabilitat. La finalitat d'aquesta metodologia és la de considerar tot el ventall possible de models ajustats i, posteriorment, seleccionar el que millor s'adapti a les dades. Coneixent i entenent tots aquests models,

també, es poden identificar patrons individuals de comportament dels clústers, que aporten informació al procés de millora, tot i que no s'acabin seleccionant com a models finals.

***Paraules clau:*** Projectes Col·laboratius, estimació bayesiana, models jeràrquics, efectes fixos i efectes aleatoris.



# ABSTRACT

**Title:** Estimation, selection and interpretation of Bayesian models to evaluate the health care improvement in collaborative projects.

**Background:** Collaborative projects are used to improve health care performance. These are multicenter studies that may have multiple sources of variability that can cause bias in the evaluation of health care improvement. A good fit in the regression models will allow obtaining optimal results.

**Objective:** To develop an efficient methodology that identifies the Bayesian model that best adjusts to the data available for assessing the improvement of quality patient care indicators. This methodology consists in estimating, selecting and interpreting Bayesian models.

**Methods:** This methodology has been implemented using Bayesian methods of fit in different steps: multiple lineal regression models and generalized models, with Binomial and Poisson responses, and fixed and random effects. Analyses were performed using the R statistic software, 2.14.0 version, using the INLA package.

**Results:** The proposed methodology has been applied in two collaborative projects: IMPIC-09 and PREVENTIONS OF FALLS, promoted by the Aliança per la Seguretat del Pacient and the Departament de Salut de Catalunya between 2007 and 2009. The best model has been selected for both projects to obtain the improvement results for each quality indicator, considering the fixed effects model for the IMPIC project, and fixed and random effects for the PREVENTION OF FALLS project.

**Conclusions:** This project has allowed validation of the gradual methodology which consisted of fitting an initial model with fixed effects and, hierarchically, adding the random effects related with clusters. The objective is to consider all the possible models and then to select the best. If we know all these models we will be able to identify individual behaviors from the clusters which add information to the improvement process.

**Key words:** *Collaborative projects, Bayesian estimation, hierarchical models, fixed effects, random effects.*



# ÍNDEX

1	INTRODUCCIÓ .....	15
1.1	ELS PROJECTES COL·LABORATIUS.....	15
1.2	ELS INDICADORS. L'EINA AVALUATIVA.....	16
1.3	L'AVALUACIÓ DE LA MILLORA .....	16
2	MÈTODES.....	19
2.1	OBJECTIUS .....	19
2.2	INFERÈNCIA BAYESIANA .....	19
2.2.1	Model Estadístic .....	19
2.2.2	Model Bayesià .....	20
2.2.3	Distribució a posteriori .....	20
2.2.4	Inferència Bayesiana .....	21
2.3	MODELS DE REGRESSIÓ BAYESIANS.....	22
2.3.1	Model de Regressió Lineal Simple.....	22
2.3.2	Model de Regressió Lineal Múltiple .....	23
2.3.3	Model Lineal Generalitzat Bayesià .....	23
2.4	MODELS JERÀRQUICS BAYESIANS .....	25
2.4.1	Model Jeràrquic Bayesià d'un nivell.....	26
2.4.2	Model Jeràrquic Bayesià de dos nivells.....	28
2.5	SELECCIÓ DE PRIORIS .....	28
2.6	SELECCIÓ DELS MODELS.....	30
2.6.1	DIC (Deviance Information Criterion).....	30
2.6.2	CPO (Conditional Predictive Ordinate).....	31
2.7	SOFTWARE ESTADÍSTIC UTILITZAT PER A L'ESTIMACIÓ DELS MODELS .....	32
3	RESULTATS.....	33
3.1	PROJECTE IMPIC-09. Projecte col·laboratiu de prevenció de la infecció quirúrgica en la cirurgia colorrectal .....	33
3.1.1	Contextualització.....	33
3.1.2	Anàlisi descriptiva de les dades.....	34
3.1.3	Estimació dels models .....	43
3.1.4	Selecció dels models .....	61
3.1.5	Interpretació dels models .....	69

3.2	PROJECTE PREVENCIÓ DE CAIGUDES: Projecte col·laboratiu de pràctiques segures en la prevenció de caigudes de pacients. ....	75
3.2.1	Contextualització.....	75
3.2.2	Anàlisi descriptiva de les dades.....	76
3.2.3	Estimació dels models .....	80
3.2.4	Selecció dels models .....	96
3.2.5	Interpretació dels models .....	103
4	CONCLUSIONS .....	109
5	REFERÈNCIES BIBLIOGRÀFIQUES.....	113

# ÍNDEX DE TAULES

Taula 1.Llistat del conjunt de Mesures Preventives de la Infecció Quirúrgica .....	33
Taula 2.Resum descriptiu de les variables demogràfiques i clíniques dels pacients intervinguts. ....	35
Taula 3.Resum descriptiu de les variables perioperatòries i operatòries de les intervencions .....	35
Taula 4.Descripció de l'acompliment de les mesures preventives en cirurgia de Còlon .....	37
Taula 5.Descripció de l'acompliment de les mesures preventives en cirurgia de recte .....	41
Taula 6.Estimació puntual i interval de confiança dels paràmetres del Model Logístic Bayesià per a l'acompliment de les mesures preventives .....	43
Taula 7.Estimació puntual i interval de confiança dels paràmetres del Model Logístic Jeràrquic Bayesià per a l'acompliment de les mesures preventives .....	44
Taula 8.Estimació puntual i interval de confiança dels paràmetres del Model Logístic Jeràrquic Bayesià amb temps com a efecte aleatori per a l'acompliment de les mesures preventives ....	45
Taula 9.Variables demogràfiques, clíniques, perioperatòries i operatòries significatives del Model Logístic Bayesià per a la infecció incisional en cirurgia de còlon .....	47
Taula 10.Variables demogràfiques, clíniques, perioperatòries i operatòries significatives del Model Logístic Jeràrquic Bayesià per a la infecció incisional en cirurgia de còlon .....	49
Taula 11.Acompliment de les mesures preventives i Mes d'estudi en el Model Logístic Jeràrquic Bayesià per a la infecció incisional en cirurgia de còlon .....	49
Taula 12.Variables demogràfiques, clíniques, perioperatòries i operatòries significatives del Model Logístic Bayesià per a la infecció òrgano-cavitària en cirurgia de còlon .....	51
Taula 13.Variables demogràfiques, clíniques, perioperatòries i operatòries significatives del Model Logístic Jeràrquic Bayesià per a la infecció òrgano-cavitària en cirurgia de còlon .....	53
Taula 14.Acompliment de les mesures preventives i Mes d'estudi en el Model Logístic Jeràrquic Bayesià per a la infecció òrgano-cavitària en cirurgia de còlon .....	53
Taula 15.Variables demogràfiques, clíniques, perioperatòries i operatòries significatives del Model Logístic Bayesià per a la infecció incisional en cirurgia de recte .....	55
Taula 16.Variables demogràfiques, clíniques, perioperatòries i operatòries significatives del Model Logístic Jeràrquic Bayesià per a la infecció incisional en cirurgia de recte .....	57
Taula 17.Acompliment de les mesures preventives i Mes d'estudi en el Model Logístic Jeràrquic Bayesià per a la infecció incisional en cirurgia de recte .....	57
Taula 18.Variables demogràfiques, clíniques, perioperatòries i operatòries significatives del Model Logístic Bayesià per a la infecció òrgano-cavitària en cirurgia de recte .....	59

Taula 19.Acompliment de les mesures preventives i Mes d'estudi en el Model Logístic Jeràrquic Bayesià per a la infecció òrgano-cavitària en cirurgia de recte .....	60
Taula 20.Criteris de selecció entre els models plantejats per avaluar la millora de l'acompliment de les mesures preventives.....	61
Taula 21.Criteris de selecció entre els models plantejats per avaluar la millora de la infecció incisional i l'impacte de les mesures preventives en cirurgia de còlon .....	64
Taula 22.Criteris de selecció entre els models plantejats per avaluar la millora de la infecció òrgano-cavitària i l'impacte de les mesures preventives en cirurgia de còlon .....	66
Taula 23.Criteris de selecció entre els models plantejats per avaluar la millora de la infecció incisional i l'impacte de les mesures preventives en cirurgia de recte.....	67
Taula 24.Criteris de selecció entre els models plantejats per avaluar la millora de la infecció òrgano-cavitària i l'impacte de les mesures preventives en cirurgia de recte .....	68
Taula 25.Llistat del conjunt de mesures preventives de les caigudes de pacient .....	75
Taula 26.Descripció de la taxa de caigudes per tipologia de centre i les diferents unitats participants. ....	76
Taula 27.Descripció de les variables relacionades amb el Programa de prevenció de caigudes i el seu contingut.....	80
Taula 28.Estimació puntual i interval de confiança dels paràmetres del Model Lineal amb Resposta Normal Bayesià per a l'acompliment de les mesures preventives.....	81
Taula 29.Estimació puntual i interval de confiança dels paràmetres del Model Lineal Jeràrquic amb resposta Normal Bayesià, amb efecte aleatori centre, per a l'acompliment de les mesures preventives.....	82
Taula 30.Estimació puntual i interval de confiança dels paràmetres del Model Lineal Jeràrquic amb resposta Normal Bayesià, amb el temps com a efecte aleatori associat al centre per a l'acompliment de les mesures preventives.....	83
Taula 31.Estimació puntual i interval de confiança dels paràmetres del Model Lineal Jeràrquic amb resposta Normal Bayesià, amb efecte aleatori unitat, per a l'acompliment de les mesures preventives.....	84
Taula 32.Estimació puntual i interval de confiança dels paràmetres del Model Lineal Jeràrquic amb resposta Normal Bayesià, amb el temps com a efecte aleatori associat a la unitat per a l'acompliment de les mesures preventives.....	84
Taula 33.Estimació puntual i interval de confiança dels paràmetres del Model Lineal Jeràrquic amb resposta Normal Bayesià, amb la unitat depenent del centre com a efectes aleatoris, per a l'acompliment de les mesures preventives.....	85
Taula 34.Variables explicatives significatives en el model Bayesià amb Resposta Poisson per a la millora de la taxa de caigudes sense tenir en compte la temps-dependència del percentatge de mesures preventives .....	87

Taula 35.Variables explicatives referents al Programa de Prevenció de caigudes significatives en el model Bayesià amb Resposta Poisson per a la millora de la taxa de caigudes sense tenir en compte la temps-dependència del percentatge de mesures preventives .....	88
Taula 36.Variables explicatives significatives en el model Bayesià amb Resposta Poisson per a la millora de la taxa de caigudes tenint en compte la temps-dependència del percentatge de mesures preventives .....	89
Taula 37.Variables explicatives referents al Programa de Prevenció de caigudes significatives en el model Bayesià amb Resposta Poisson per a la millora de la taxa de caigudes tenint en compte la temps-dependència del percentatge de mesures preventives .....	89
Taula 38.Variables explicatives significatives en el model Jeràrquic amb Resposta Poisson, amb efecte aleatori centre, per a la millora de la taxa de caigudes tenint en compte la temps-dependència del percentatge de mesures preventives.....	91
Taula 39.Variables explicatives significatives en el model Jeràrquic amb Resposta Poisson, amb efecte aleatori unitat, per a la millora de la taxa de caigudes tenint en compte la temps-dependència del percentatge de mesures preventives.....	93
Taula 40.Variables explicatives referents al contingut del Programa de Prevenció de caigudes significatives en el model Jeràrquic amb Resposta Poisson, amb efecte aleatori unitat, per a la millora de la taxa de caigudes tenint en compte la temps-dependència del percentatge de mesures preventives .....	93
Taula 41.Variables explicatives significatives en el model Jeràrquic amb Resposta Poisson, amb efecte aleatori unitat dependent de l'efecte aleatori centre, per a la millora de la taxa de caigudes tenint en compte la temps-dependència del percentatge de mesures preventives...	95
Taula 42.Variables explicatives referents al contingut del Programa de Prevenció significatives en el model Jeràrquic amb Resposta Poisson, amb efecte aleatori unitat dependent de l'efecte aleatori centre, per a la millora de la taxa de caigudes tenint en compte la temps-dependència del percentatge de mesures preventives.....	96
Taula 43.Criteris de selecció entre els models plantejats per avaluar la millora de l'acompliment de les mesures preventives.....	97
Taula 44.Criteris de selecció entre els models plantejats per avaluar la millora de la taxa de caigudes i l'impacte de les mesures preventives .....	101





# ÍNDEX DE GRÀFICS

Gràfic 1. Intervencions quirúrgiques colorrectals observades en els 24 hospitals.....	34
Gràfic 2.Distribució de les taxes d'infecció incisionals i òrgano-cavitàries en cirurgia de còlon .....	36
Gràfic 3.Distribució del percentatge de compliment de les mesures preventives en cirurgia de còlon.....	38
Gràfic 4.Evolució de la infecció i l'acompliment de les mesures preventives en cirurgia de còlon .....	39
Gràfic 5.Distribució de les taxes d'infecció incisionals i òrgano-cavitàries en cirurgia de recte .....	40
Gràfic 6.Distribució del percentatge de compliment de les mesures preventives en cirurgia de recte .....	41
Gràfic 7.Evolució de la infecció i l'acompliment de les mesures preventives en cirurgia de recte .....	42
Gràfic 8.Efectes aleatoris dels hospitals associats al compliment de les mesures preventives estimats a partir del model 2. ....	62
Gràfic 9.Efectes aleatoris dels hospitals associats al compliment de les mesures preventives estimats a partir del model 3. ....	62
Gràfic 10.Efectes aleatoris de la millora del compliment de les mesures preventives dels hospitals estimats a partir del model 2.....	63
Gràfic 11.Efectes aleatoris dels hospitals associats a la infecció incisional en cirurgia de còlon estimats a partir del model 2. ....	64
Gràfic 12.Efectes aleatoris dels hospitals associats a la infecció òrgano-cavitària en cirurgia de còlon estimats a partir del model 2. ....	65
Gràfic 13.Efectes aleatoris dels hospitals associats a la infecció incisional en cirurgia de recte estimats a partir del model 2. ....	67
Gràfic 14.Efectes aleatoris dels hospitals associats a la infecció òrgano-cavitària en cirurgia de recte estimats a partir del model 2. ....	68
Gràfic 15.Distribucions a posteriori dels paràmetres del model seleccionat per a l'avaluació de la millora de l'acompliment de les mesures preventives.....	69
Gràfic 16.Distribucions a posteriori dels paràmetres del model seleccionat per a l'avaluació de la millora de la infecció incisional i l'impacte de les mesures preventives en cirurgia de còlon	70
Gràfic 17.Distribucions a posteriori dels paràmetres del model seleccionat per a l'avaluació de la millora de la infecció òrgano-cavitària i l'impacte de les mesures preventives en cirurgia de còlon.....	72
Gràfic 18.Distribucions a posteriori dels paràmetres del model seleccionat per a l'avaluació de la millora de la infecció incisional i l'impacte de les mesures preventives en cirurgia de recte.	73

Gràfic 19.Distribucions a posteriori dels paràmetres del model seleccionat per a l'avaluació de la millora de la infecció òrgano-cavitària i l'impacte de les mesures preventives en cirurgia de recte .....	74
Gràfic 20.Evolució de la taxa de caigudes i l'acompliment de les mesures preventives .....	77
Gràfic 21.Evolució de la taxa de caigudes i l'acompliment de les mesures preventives de les diferents unitats participants dels centres sociosanitaris.....	78
Gràfic 22.Evolució de la taxa de caigudes i l'acompliment de les mesures preventives de les diferents unitats participants dels hospitals .....	79
Gràfic 23.Efectes Aleatoris de l'acompliment dels Centres estimats amb el model 2 .....	98
Gràfic 24.Efectes Aleatoris de la millora dels Centres estimats amb el model 2.B .....	98
Gràfic 25.Efectes Aleatoris de l'acompliment de les Unitats estimats amb el Model 3 .....	99
Gràfic 26.Efectes Aleatoris de la millora de les Unitats estimats amb el Model 3.B .....	100
Gràfic 27.Efecte dels centres en la taxa de caigudes estimats amb el model 2 .....	101
Gràfic 28.Efecte dels centres en la millora de la taxa de caigudes estimats amb el model 2.B .....	102
Gràfic 29.Efecte de les unitats en la taxa de caigudes estimats amb el model 3 .....	102
Gràfic 30.Efecte de les unitats en la millora de la taxa de caigudes estimats amb el model 3.B .....	103
Gràfic 31.Distribució a posteriori dels efectes fixos del model estimat per a l'avaluació de la millora de l'acompliment de les mesures preventives de les caigudes .....	104
Gràfic 32.Distribució a posteriori dels efectes fixos del model estimat per a l'avaluació de la millora de la taxa de caigudes preventives i l'impacte de les mesures preventives i el Programa de Prevenció de Caigudes .....	105
Gràfic 33.Distribució a posteriori dels efectes fixos del model estimat per a l'avaluació de la l'impacte del contingut del Programa de Prevenció de Caigudes .....	106



# 1 INTRODUCCIÓ

## 1.1 ELS PROJECTES COL-LABORATIUS

Dins l'àmbit de la seguretat de l'atenció al pacient, ja fa uns anys, gaudeixen d'un creixement significatiu el que s'anomenen **projectes col·laboratius**. Aquests s'entenen com una estratègia utilitzada per a la implementació de pràctiques basades en la evidència dins l'atenció sanitària, i s'inicien amb la identificació d'un tema on la diferència entre la situació actual i la recomanada (o l'estàndard) suposa un problema per a la seguretat del pacient. Un cop identificada la raó d'estudi, es crea un *grup d'experts* encarregats de construir un *conjunt de mesures basades en l'evidència* per intentar reduir aquesta distància observada, i es proposa als professionals dels centres relacionats amb la temàtica unir-se a la realització dels esforços necessaris per millorar. És en aquest moment, quan s'adhereixen al projecte un conjunt de centres participants que treballen unànimement en el tema proposat durant un període de temps especificat (normalment, un any). Aquest treball s'acompanya de la realització d'una sèrie de reunions on els participants aprenen tècniques de millora i comparteixen les seves experiències en la implementació de les noves pràctiques en els seus centres. Un cop acabat el col·laboratiu, els participants presenten els seus resultats obtinguts a d'altres organitzacions no participants en el projecte en diferents conferències.

L'*Aliança per la Seguretat del Pacient* és una estratègia derivada de l'Institut Universitari Avedis Donabedian que té com a principal objectiu estimular actuacions implicant tots els grups d'interès per tal d'impulsar les millores necessàries per millorar la seguretat. Aquesta estratègia, iniciada el 2005, coopera juntament amb el Departament de Salut per coordinar un seguit de projectes col·laboratius entre els centres de salut i sociosanitaris de Catalunya abordant diferents tipus de problemes, com la infecció en l'espai quirúrgic de les intervencions colorrectals, les caigudes de pacients, la identificació de pacients i molts d'altres.

## 1.2 ELS INDICADORS. L'EINA AVALUATIVA.

Avaluar l'impacte ocasionat sobre la pràctica clínica de les organitzacions participants per la intervenció realitzada mitjançant un projecte col·laboratiu, es tradueix a l'avaluació de la millora d'un conjunt d'indicadors, especificats a l'inici d'aquest pel grup d'experts. Un indicador pot ser un quocient entre casos favorables i casos possibles (*proporció* o *percentatge*) o un quocient entre esdeveniments i unitats temporals o d'espai (*taxa*), i reflecteixen aspectes estructurals, de procés i resultat dels centres participants.

- **INDICADORS D'ESTRUCTURA:** indiquen com està organitzat i equipat el centre. Permeten saber si els recursos estan disponibles i organitzats per tal de facilitar la seguretat i l'atenció del pacient.
- **INDICADORS DE PROCÉS:** indiquen com és l'atenció que es dona en el centre. Mesuren si tots els passos de l'atenció al pacient es fan correctament. Tot indicador de procés està vinculat a un de resultat.
- **INDICADORS DE RESULTAT:** indiquen l'efectivitat de l'atenció i el grau en que aquesta produeix l'efecte desitjat en el pacient. Poden reflectir aspectes desitjats o adversos.

El projecte col·laboratiu té com a objectiu millorar en relació als indicadors de procés per, indirectament, millorar els de resultat.

## 1.3 L'AVALUACIÓ DE LA MILLORA

Un dels esforços que es demanen per part dels participants del col·laboratiu és la medició periòdica (quinzenal, mensual, bimensual,...) dels indicadors especificats. Aquest punt és molt important perquè d'aquesta manera les organitzacions coneixen els seus resultats individuals al mateix temps que estan aplicant els canvis. Hi ha diferents tècniques estadístiques per avaluar aquests resultats instantàniament, però aquestes no són objecte d'interès d'aquest treball. Sobre al que a nosaltres interessa, **al final del projecte col·laboratiu** es disposarà d'una base de dades amb un conjunt de variables corresponents als indicadors i una variable temporal que servirà per avaluar la millora d'aquests indicadors, **a nivell global de tots els centres participants**. Aquesta estimació de la millora dels indicadors de qualitat, definits pel

projecte col·laboratiu, ha de fer-se tenint en compte alguns factors característics d'aquest tipus d'estudis.

Com a conseqüència de l'objectiu d'aquests indicadors, definit per l'avaluació de les pràctiques de l'atenció o la seva efectivitat en els usuaris de cada un dels centres, la seva construcció es basa sobre la observació dels seus pacients. Aquest fet origina diferents fonts de variabilitat, per una banda la ocasionada pel pacient, i per una altra la que explica el mateix centre o organització participant, i fa que les dades disponibles per a la avaluació de la millora presentin una estructura jeràrquica que caldrà tractar adequadament. Aquest tractament consisteix en l'estimació de models de regressió que tinguin en compte els efectes fixes i aleatoris causants de la variabilitat. Per a aconseguir aquests models s'haurà de definir una metodologia que permeti tenir en compte totes les opcions possibles que estimin sense biaix la millora dels indicadors.

A continuació es posa en pràctica una metodologia dissenyada per a l'avaluació de la millora d'un conjunt d'indicadors elaborats a partir de dos projectes col·laboratius duts a terme per l'Aliança de la Seguretat del Pacient i el Departament de Salut: IMPIC-09 i PREVENCIÓ DE CAIGUDES. Aquest projecte té com a objectiu definir un procés per tal de tenir en compte totes les fonts de variabilitat originades en els resultats de les mesures fetes amb els indicadors i, d'aquesta manera, assolir la òptima estimació de la millora.



## 2 MÈTODES

En aquest capítol s'introdueixen els mètodes estadístics que s'han utilitzat en aquest projecte per a obtenir les respostes associades als objectius plantejats.

### 2.1 OBJECTIUS

Desenvolupar una metodologia eficaç per identificar el model de regressió bayesià que millor s'ajusti a les dades disponibles per a l'avaluació de la millora dels indicadors de qualitat de l'atenció al pacient dels centres sanitaris. Aquesta metodologia consisteix en:

- Estimar els models de regressió Bayesians que es considerin oportuns.
- Seleccionar el model de regressió Bayesià que s'adapti millor a les dades disponibles d'entre el conjunt dels estimats.
- Interpretar el model de regressió Bayesià seleccionat.

### 2.2 INFERÈNCIA BAYESIANA

#### 2.2.1 Model Estadístic

**Definició 1.** El model estadístic és una llista de models de probabilitat indexats per un paràmetre  $\theta \in \Omega$ .

$$M = \{P(y|\theta) : \theta \in \Omega\}$$

On  $P(y|\theta)$  és el model de probabilitat,  $\theta$  és el paràmetre del model i  $\Omega$  és l'espai paramètric.



La inferència consisteix en, un cop observades les dades, identificar quin model de probabilitat pertanyent a  $M$  ha generat les dades.

### 2.2.2 Model Bayesià

Si partim del model estadístic, el model Bayesià es diferencia del model estadístic per la incorporació de la *distribució a priori* en aquest últim. La distribució a priori aporta al model estadístic la informació prèvia que l'investigador coneix del paràmetre que es vol estimar. D'aquesta manera, el model Bayesià combina la informació que aporten les dades a partir del model de probabilitat i la informació teòrica que es coneix sobre paràmetre  $\theta$ .

**Definició 2.** El model Bayesià és una llista de models de probabilitat ordenats probabilísticament en funció de  $\Pi(\theta)$ .

$$M = \{P(y|\theta) : \theta \in \Omega\}$$

$$\Pi(\theta)$$

On  $P(y|\theta)$  és el model de probabilitat,  $\theta$  és el paràmetre del model,  $\Omega$  és l'espai paramètric i  $\Pi(\theta)$  és la distribució a priori del paràmetre  $\theta$ .

### 2.2.3 Distribució a posteriori

Partint del model Bayesià  $\left\{ \begin{matrix} M = \{P(y|\theta) : \theta \in \Omega\} \\ \Pi(\theta) \end{matrix} \right\}$  y un cop observades les dades  $Y = y$ , volem inferir sobre el paràmetre  $\theta$ , és a dir, conèixer la distribució del paràmetre condicionada a les dades observades  $y$ .

**Definició 3.** La distribució a posteriori del paràmetre  $\theta$ ,  $\Pi(\theta|y)$ , es defineix con la distribució del paràmetre  $\theta$  un cop conegudes les dades  $Y = y$ . Aquesta distribució es pot conèixer aplicant el TEOREMA DE BAYES.

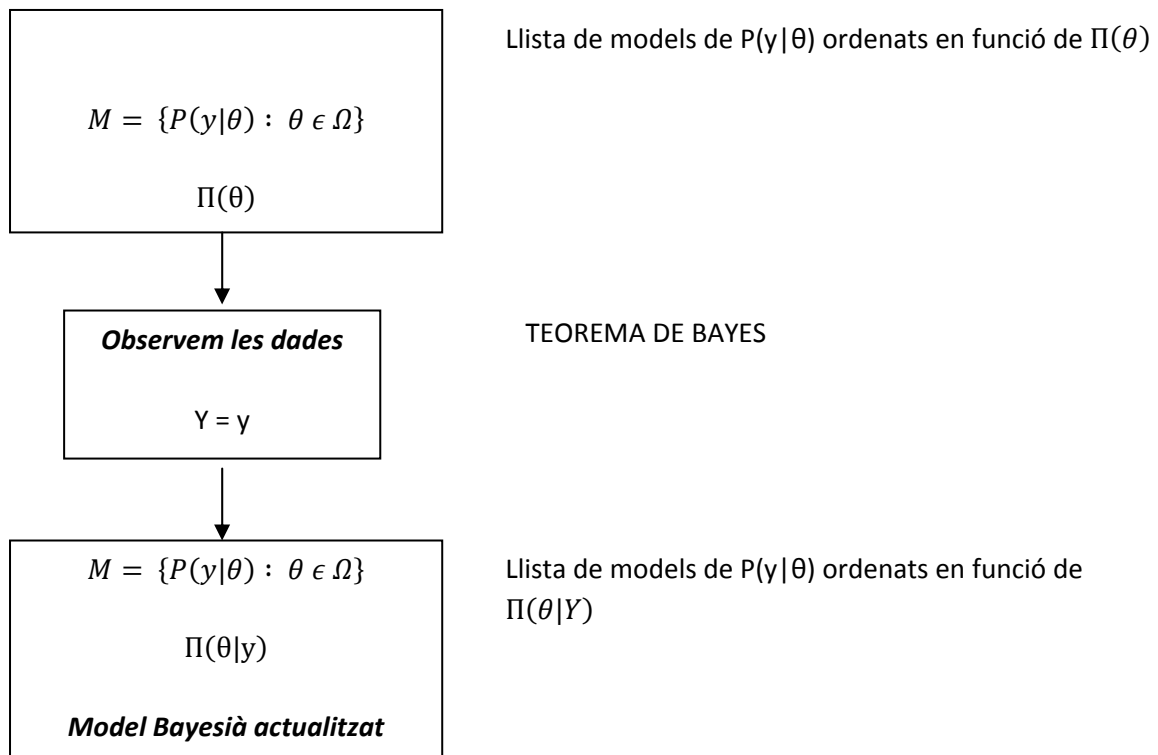
$$\Pi(\theta|y) = \frac{P(y, \theta)}{P_{\Pi}(y)} = \frac{P(y|\theta)\Pi(\theta)}{\int_{\Omega} P(y|\theta)\Pi(\theta)d\theta}$$

On  $P(y, \theta)$  és la probabilitat conjunta d' $y$  i  $\theta$ ,  $P_{\Pi}(y)$  és la DISTRIBUCIÓ PREDICTIVA A PRIORI (o la marginal de  $y$ ),  $P(y|\theta)$  és el model de probabilitat de  $y$  i  $\Pi(\theta)$  és la distribució a priori de  $\theta$ .

Un cop estimada la distribució a posteriori del paràmetre ja es poden fer les estimacions sobre aquest que es vulguin.

#### 2.2.4 Inferència Bayesiana

Els següent diagrama mostra com es realitza la inferència amb l'enfocament Bayesià.



La inferència sobre el paràmetre  $\theta$  es farà a partir del Model Bayesià actualitzat un cop s'han observat les dades  $Y=y$ .

## 2.3 MODELS DE REGRESSIÓ BAYESIANS

### 2.3.1 Model de Regressió Lineal Simple

Suposem el següent model on  $Y_i$  representa el valor de la variable resposta per cada un de l' $i$ -èssim individu avaluat i  $X_i$  el valor que pren aquest per a una variable explicativa d'interès. El Model de Regressió Lineal Simple associa una recta entre el valor esperat de la variable resposta  $Y_i$  i el valor de la variable explicativa  $X_i$ .

Considerem que la variable resposta  $Y_i$  segueix una distribució Normal amb mitjana  $\mu_i$  i desviació estàndard  $\sigma$ , llavors definim  $\tau = 1/\sigma^2$  com el paràmetre de precisió.

$$Y_i \sim \text{Normal}(\mu_i, \tau), \quad i = 1, \dots, n$$
$$\mu_i = \beta_0 + \beta_1 X_i$$

A partir d'aquest model de regressió es vol estimar l'efecte  $\beta_1$  de la variable explicativa  $X_i$  sobre la variable resposta  $Y_i$ . Per fer l'estimació sota l'enfocament Bayesià cal definir les distribucions a priori per cada un dels paràmetres d'interès. En aquest cas, el vector de paràmetres és  $\theta = \{\beta_0, \beta_1, \tau\}$ .

Així, el Model de Regressió Lineal Simple Bayesià quedarà especificat de la següent manera:

$$Y_i \sim \text{Normal}(\mu_i, \tau), \quad i = 1, \dots, n$$
$$\mu_i = \beta_0 + \beta_1 X_i$$
$$\Pi(\beta_0)$$
$$\Pi(\beta_1)$$
$$\Pi(\tau)$$

### 2.3.2 Model de Regressió Lineal Múltiple

Si partim del model anterior on només consideràvem una variable explicativa  $X_i$  i l'ampliem afegint-hi  $k$  variables explicatives més, el model serà el següent.

$$Y_i \sim \text{Normal}(\mu_i, \tau), \quad i = 1, \dots, n$$

$$\mu_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_k X_{ki}$$

Com que han augmentat el número de paràmetres a estimar, hauran d'augmentar, també, el nombre de distribucions a priori a definir. El model de regressió lineal múltiple Bayesià queda definit de la següent manera.

$$Y_i \sim \text{Normal}(\mu_i, \tau), \quad i = 1, \dots, n$$

$$\mu_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_k X_{ki}$$

$$\Pi(\beta_0)$$

$$\Pi(\beta_1)$$

$$\Pi(\beta_2)$$

$$\vdots$$

$$\Pi(\beta_k)$$

$$\Pi(\tau)$$

### 2.3.3 Model Lineal Generalitzat Bayesià

Fins ara hem considerat dos models on la variable resposta  $Y_i$  es distribuïa de manera  $\text{Normal}(\mu_i, \tau)$ . Per especificar el Model Lineal Generalitzat partirem del model anterior generalitzant-lo pel conjunt de variables pertanyents a la família exponencial.

**Definició 4:** Una variable aleatòria  $X$  pertany a la família exponencial si la seva funció de densitat depèn d'un paràmetre  $\theta \in \Omega \subseteq \mathbb{R}^p$  y es pot escriure com:

$$f(x|\theta) = h(x)c(\theta)\exp\left(\sum_{j=1}^k w_j(\theta)t_j(x)\right)$$

El model lineal generalitzat Bayesià queda especificat amb l'expressió següent.

$$Y_i \sim \text{Família exponencial}(\theta_i), \quad i = 1, \dots, n$$

$$E[Y_i|\beta_0, \dots, \beta_k] = \mu_i$$

$$\eta = g(\mu_i) = \beta_0 + \beta_1 X_i + \beta_2 X_i + \dots + \beta_k X_i$$

$$\Pi(\beta_0)$$

$$\Pi(\beta_1)$$

$$\Pi(\beta_2)$$

$$\vdots$$

$$\Pi(\beta_k)$$

Si ens hi fixem bé, observarem que la diferència entre el Model Lineal Generalitzat i el Model de Regressió Lineal és que, mentre el Model de Regressió Lineal ajusta una recta entre el valor esperat de la variable resposta,  $\mu_i$ , i les variables explicatives, en el Model Lineal Generalitzat aquesta recta es modela per a una funció del valor esperat de la variable resposta,  $\eta$ , anomenada **funció enllaç** (funció link).

Les funcions d'enllaç que utilitzarem en aquest treball són:


Logit: utilitzada per a models amb variable resposta binària.  $\eta = \log\left(\frac{\theta}{1-\theta}\right)$ , on  $\theta = E[Y] = P(Y = 1)$  quan  $Y \sim \text{Bernoulli}(\theta)$ .

Log-lineal: utilitzada per a models amb variable resposta amb funció de distribució Poisson.  $\eta = \log(\theta)$ , on  $\theta = E[Y]$  quan  $Y \sim \text{Poisson}(\theta)$ .

## 2.4 MODELS JERÀRQUICS BAYESIANS

Fins ara hem considerat que les observacions dels models anteriors complien la condició d'independència.

Suposem ara que volem estimar un model per una variable resposta observada en un conjunt de pacients seleccionats a l'atzar de  $j$  centres hospitalaris diferents. Es pot pensar que els pacients que pertanyen a un mateix centre hospitalari tinguin algun comportament diferenciat dels pacients que han estat seleccionats d'un altre centre. Aquestes diferències poden explicar-se per característiques dels professionals, entorn del centre, tipologia dels malalts i poden convertir-se en una font de variabilitat. En aquest cas, doncs, els pacients no són independents entre ells i el mètode de regressió explicat anteriorment no realitzaria bones estimacions.



Una bona manera de controlar la variabilitat que aporten al model els hospitals seria a partir de Models Jeràrquics.

La diferència entre els Models de Regressió Lineals i els Models Jeràrquics es troba en la diferenciació de dos tipus d'efectes a estimar:

- Els **efectes fixes** estan associats a l'efecte de les variables explicatives sobre la variable resposta. És homogeni per a totes les observacions.
- Els **efectes aleatoris** estan associats als blocs o conglomerats que creiem que podrien aportar variabilitat en la resposta i per als quals s'haurien d'ajustar al model. Corresponen a l'efecte de pertànyer a un bloc determinat sobre la variable resposta. També poden relacionar l'efecte d'una variable explicativa en funció del bloc considerat.

#### 2.4.1 Model Jeràrquic Bayesià d'un nivell

Suposem que tenim  $m$  blocs amb  $n_i$  observacions cada un i  $\sum_{i=1}^m n_i = N$  és el nombre total d'observacions. Definim com a efectes fixes aquells associats a les variables explicatives  $X = (X_1, X_2, \dots, X_p)$  i com a únic efecte aleatori el relacionat amb els  $m$  blocs. Definim el Model Jeràrquic Bayesià d'un nivell com:

$$Y_{ij} \sim \text{Família Exponencial}(\theta_{ij})$$

$$i = 1, \dots, m \text{ blocs}$$


$$j = 1, \dots, n_i \text{ observacions}$$

$$E[Y_{ij} | \beta, b_i] = \mu_{ij}$$

$$\eta = g(\mu_{ij}) = \beta X_{ij} + b_i$$

$$\Pi(\beta), \Pi(b_i)$$

On  $\beta = (\beta_0, \beta_1, \dots, \beta_p)$  és el vector de dimensions  $(1 \times p)$  dels coeficients dels efectes fixes i  $b_i$  representa l'efecte aleatori dels  $m$  blocs. Aquests valors  $b_i$  els podríem interpretar com la diferència en el valor de la variable resposta  $Y$  quan el valor de les variables explicatives és 0 entre els diferents blocs. És a dir, el valor de la variable resposta  $Y$  per cada un dels blocs ajustat per les variables explicatives.



Aquest gràfic representa la relació lineal entre la variable  $Y$  i  $X$  en 4 blocs diferents. Observem que la pendent de les rectes és la mateixa per tots el blocs (efecte fix de la variable  $X$ ), mentre que el valor inicial de la recta és diferent per cada bloc (efecte aleatori bloc).

Si un dels nostres objectius és conèixer si una variable d'interès  $Z$  experimenta efectes diferents sobre la variable resposta  $Y$  dependent del bloc, podríem formular el model de la següent manera.

$$Y_{ij} \sim \text{Família Exponencial}(\theta_{ij})$$

$$i = 1, \dots, m \text{ blocs}$$


$$j = 1, \dots, n_i \text{ observacions}$$

$$E[Y_{ij} | \beta, b_i] = \mu_{ij}$$

$$\eta = g(\mu_{ij}) = X_{ij}\beta + Z_{ij}b_i$$

$$\Pi(\beta), \Pi(b_i)$$

On  $b_i = (b_{i0}, b_{i1})$  representaria el punt de partida de la variable  $Y$  i la pendent de la recta, és a dir, l'efecte de la variable  $Z$  sobre la variable  $Y$ , per cada bloc.



Aquest gràfic representa la relació lineal entre la variable  $Y$  i  $Z$  en 4 blocs diferents. Observem que la pendent de les rectes ha canviat segons el bloc (la variable  $Z$  té efectes diferents en cada un dels blocs respecte la  $Y$ ) i el valor inicial de la recta és diferent per cada bloc (efecte aleatori bloc).



### 2.4.2 Model Jeràrquic Bayesià de dos nivells

A partir del model especificat anteriorment podem suposar que dels  $m$  blocs hi depenen  $k_i$  sub-blocs amb  $n_{ij}$  observacions cada un, on  $\sum_{i=1}^m k_i = K$  és el nombre total de sub-blocs i  $\sum_{i=1}^m \sum_{j=1}^{k_i} n_{ij} = N$  és el nombre total d'observacions. Definim com a efectes fixes aquells associats a les variables explicatives  $X = (X_1, X_2, \dots, X_p)$  i com a efectes aleatoris els relacionats amb els  $m$  blocs i els dependents  $k_i$  sub-blocs. Definim el Model Jeràrquic Bayesià de dos nivells com:

$$\begin{aligned} Y_{ij} &\sim \text{Família Exponencial}(\theta_{ij}) \\ i &= 1, \dots, m \text{ blocs} \\ j &= 1, \dots, k_i \text{ sub-blocs} \\ l &= 1, \dots, n_{ij} \text{ observacions} \\ E[Y_{ij} | \beta, b_i, b_{ij}] &= \mu_{ij} \\ \eta &= g(\mu_{ij}) = X_{ijl}\beta + b_i + b_{ij} \\ \Pi(\beta), \Pi(b_i), \Pi(b_{ij}) \end{aligned}$$


On  $\beta = (\beta_0, \beta_1, \dots, \beta_p)$  és el vector de dimensions  $(1 \times p)$  dels coeficients dels efectes fixes i  $b_i$  representa l'efecte aleatori dels  $m$  blocs i  $b_{ij}$  l'efecte aleatori associat als sub-blocs.

## 2.5 SELECCIÓ DE PRIORIS

A l'hora d'utilitzar mètodes d'inferència Bayesiana, un dels principals dilemes amb el que l'estadístic es pot trobar és el d'escollir la distribució a priori del paràmetre.

La selecció de la distribució a priori es basarà en el grau de coneixement previ que es tingui sobre el paràmetre. D'aquesta manera, quan l'investigador o l'expert disposi d'informació que cal tenir en compte a l'hora d'estimar un paràmetre, s'utilitzarà una *distribució a priori informativa*, de reduïda variabilitat, que aportarà informació complementària a les dades;

inversament, en situacions on no es té informació creïble sobre el paràmetre, es farà servir una *distribució a priori no informativa o plana*.



La primera distribució ens indica que els valors del paràmetre  $\theta$  es poden trobar entre el 0.4 i el 0.8, donant una màxima probabilitat als valors al voltant del 0.6. Pel que fa a la segona distribució, podem observar que existeix més variabilitat i que les altes probabilitats estan associades als valors compresos entre el 0.2 i el 0.8. Per últim, la distribució plana assigna la mateixa probabilitat a tots els valors compresos entre 0 i 1.

Per als models que s'ajustaran en aquest projecte, utilitzarem prioris planes o no informatives ja que no disposem d'informació de l'efecte de les variables sobre la resposta que volem estimar.

## 2.6 SELECCIÓ DELS MODELS

### 2.6.1 DIC (Deviance Information Criterion)

**Definició 6:** La deviança és una mesura de la bondat d'ajust d'un model definida a partir de la funció de versemblança.

$$D(\theta) = -2\log(P(y|\theta))$$

Aquest valor serà més petit quan més ajustat es trobi el model.

Com que el model bayesià estimarà la distribució a posteriori de  $\theta$ , també obtindrem la distribució a posteriori de la deviança  $D(\theta)$ . Per tant, com a estimació puntual de  $D(\theta)$  podem prendre la mitjana d'aquesta distribució a posteriori i obtindre l'estimació puntual,  $\bar{D}(\theta)$ .

No obstant, la deviança presenta el problema que com més parametritzat es trobi el model, el seu valor disminueix i, conseqüentment, millor ajust sembla que presenti el model. És per aquesta raó que es proposa penalitzar la complexitat del model per a poder seleccionar el model més adequadament.

**Definició 7:** El número de paràmetres efectius del model,  $p_D$ , és l'estimador utilitzat per a la complexitat del model.

$$p_D = \bar{D}(\theta) - D(\bar{\theta})$$

El número de paràmetres efectius del model es defineix com la diferència entre l'estimació puntual de la deviança del model i la deviança calculada a partir de l'estimació puntual dels paràmetres.

Aquest valor serà més gran quan més complex i parametritzat es trobi el model.

**Definició 8:** El criteri DIC de selecció del model combina la mesura de la bondat d'ajust del model i la penalització per la complexitat del mateix.

$$DIC = \bar{D}(\theta) + p_D$$

Seguint el criteri de seleccionar el millor model, és millor aquell que tingui un DIC més petit, tot i que la diferència és substancialment millor quan és superior a 3.

### 2.6.2 CPO (Conditional Predictive Ordinate)

Quan el logaritme de la funció de versemblança del model és còncava o no convergeix (models molt complexes) llavors, el número de paràmetres efectius del model,  $p_D$ , és negatiu i, per tant, el DIC no pot servir per comparar model. En aquests casos, el DIC no pot fer-se servir com a criteri de selecció de models i cal utilitzar un altre valor.

**Definició 9:** El CPO es defineix com la densitat predictiva de l'observació  $i$ -èssima condicionada a totes les altres.

$$\Pi(y_i | y_{-i})$$

Un valor gran del CPO per a l'observació  $i$ -èssima es tradueix a una millor concordança amb la resta de les dades  $i$ , per tant, un millor ajust del model.

Per a la selecció del model s'obté la mitja d'aquesta distribució que és convenient que sigui el més gran possible.

En els casos pràctics d'aquest projecte, al utilitzar majoritàriament el logaritme del CPO per als models amb resposta Binomial i Poisson, s'ha calculat el valor negatiu d'aquest logaritme i, per tant, a l'hora de seleccionar el millor model s'ha seguit el criteri de com més petit el valor, millor.

## 2.7 SOFTWARE ESTADÍSTIC UTILITZAT PER A L'ESTIMACIÓ DELS MODELS

La inferència bayesiana ha estat durant molts anys en estat latent per la dificultat que representava obtindre la distribució a posteriori dels paràmetres, ja que en molts casos consistia en resoldre integrals molt complexes. Va ser a partir de les Cadenes de Markov de Monte Carlo (MCMC) quan, mitjançant la simulació, es podia trobar la forma aproximada d'aquestes integrals i, d'aquesta manera, obtenir la distribució a posteriori.

Les tècniques MCMC són, avui en dia, les més utilitzades a l'hora de resoldre problemes d'inferència bayesiana, però en moltes ocasions aquestes tècniques presenten problemes de convergència de les cadenes i el cost computacional pot ser molt gran.

***Integrated Nested Laplace Approximation (INLA)*** és una eina nova per a la inferència bayesiana que substitueix les tècniques MCMC per aproximacions deterministes de la distribució marginal a posteriori.

L'Inla té l'avantatge que es poden obtenir resultats molt més ràpid que amb les tècniques de simulació MCMC i també té accés des del software estadístic R a partir de la llibreria INLA.

Per a l'estimació de tots els models d'aquest projecte s'ha utilitzat els software R, en la seva versió 2.14.0, amb la llibreria INLA.

## 3 RESULTATS

### 3.1 PROJECTE IMPIC-09. Projecte col·laboratiu de prevenció de la infecció quirúrgica en la cirurgia colorrectal

#### 3.1.1 Contextualització

Durant l'any 2009, a partir de l'Aliança per la Seguretat del Pacient i el Departament de Salut, es va dur a terme un estudi col·laboratiu entre alguns hospitals de Catalunya per aconseguir millorar la implantació d'un conjunt de mesures preventives de la Infecció de l'Espai Quirúrgic (IEQ) en pacients intervinguts quirúrgicament de càncer de còlon i de recte.

Durant un període de 9 mesos, un responsable de cada hospital introduïa tots els pacients operats en un qüestionari electrònic i anotava si se li havien aplicat correctament el conjunt de mesures preventives, si aquest pacient havia desenvolupat una infecció i un conjunt de variables relacionades amb la tipologia de la intervenció i del pacient.

*Taula 1. Llistat del conjunt de Mesures Preventives de la Infecció Quirúrgica*

<b>Mesures preoperatòries</b>	◆ Dutxa del pacient
	◆ Glicèmia preoperatòria. En diabètics es sol·licitarà el nivell de la HbA 1c.
	◆ Tall del borrisol amb màquina elèctrica d'un sol ús.
	◆ No realitzar preparació mecànica del còlon.
<b>Mesures peri-operatòries</b>	◆ Antibiótics profilàctics: de 60 a 30 minuts abans de la cirurgia.
	◆ Mesures per assegurar la normotèrmia.
	◆ Canvi de bata al tancament de la laparotomia o ús de bata impermeable.
	◆ Canvi de guants al tancament de la laparotomia.
	◆ Nova taula i material específic per al tancament de la laparotomia.
	◆ Camp sec al tancament de la laparotomia.
	◆ Rentat de la ferida quirúrgica abans del tancament cutani.
	◆ Determinació de la glucèmia en pacients diabètics.
	◆ Si glucèmia > 200 mg/dl, aplicar el protocol de control per a reduir la glucèmia a les 48 hores

A partir d'aquest projecte, es volen respondre les següents preguntes per a les intervencions quirúrgiques realitzades en pacients amb càncer de còlon i pacients amb càncer de recte, per separat.

1 – Ha millorat l'aplicació de les mesures preventives?


2 – Ha millorat la infecció en l'Espai Quirúrgic?

3 – Ha tingut algun impacte sobre la IEQ haver aplicat el conjunt de mesures preventives?

### 3.1.2 Anàlisi descriptiva de les dades

Un total de 24 hospitals de Catalunya van participar al projecte IMPIC durant el 2009, observant 995 intervencions quirúrgiques. La distribució de la procedència d'aquestes intervencions no és uniforme en els 24 hospitals participants, sinó que s'ha observat un rang que va de 3 a 102 registres, amb una mitjana de 42 intervencions per centre.

*Gràfic 1. Intervencions quirúrgiques colorrectals observades en els 24 hospitals*



Taula 2. Resum descriptiu de les variables demogràfiques i clíniques dels pacients intervinguts

		N	%			N	%
<b>Edat</b>	≤ 65	346	34.77	<b>Antecedents de</b>	<b>No</b>	849	85.33
	> 65	649	65.23	<b>Laparotomia</b>	<b>Si</b>	146	14.67
<b>Sexe</b>	Home	581	58.45	<b>Pèrdua de pes &gt;10%</b>	<b>No</b>	887	89.15
	Dona	413	41.55		<b>Si</b>	108	10.85
<b>IMC</b>	<30	803	192	<b>Antecedents de</b>	<b>No</b>	965	96.98
	≥30	80.70	19.30	<b>corticoides</b>	<b>Si</b>	30	30.15
<b>HTA</b>	No	528	53.07	<b>Índex Charlson</b>	<2	516	51.86
	Si	467	46.93		≥2	479	48.14
<b>Cardiopatia isquèmica</b>	No	900	90.54	<b>Hemoglobina</b>	≤ 10 o >18	167	18.87
	Si	94	9.46		11 - 18	718	81.13
<b>Arritmia per fibrilació auricular</b>	No	916	92.06	<b>ASA</b>	I – II	609	61.33
	Si	79	7.94		III - IV	384	38.67
<b>Diabetis</b>	No	798	80.20	<b>Radioteràpia</b>	<b>No</b>	813	81.79
	Si	197	19.80		<b>Si</b>	181	18.21
<b>Fumador</b>	No	876	88.13	<b>Glucèmia</b>	≤ 200 mg/dl	954	97.35
	Si	118	11.87		> 200 mg/dl	26	2.65

Taula 3. Resum descriptiu de les variables perioperatòries i operatòries de les intervencions

		N	%			N	%
<b>Tipus de cirurgia</b>	<b>Oberta</b>	534	53.67	<b>Transfusió perioperatòria</b>	<b>No</b>	817	82.19
	<b>Laparoscòpica - Reconversió</b>	461	46.33		<b>Si</b>	177	17.81
<b>Cirurgia</b>	<b>Staff</b>	937	94.17	<b>Anastomosi</b>	<b>No</b>	141	14.17
	<b>Resident</b>	58	5.83		<b>Si</b>	854	85.83
<b>Hora d'administració de l'antibiòtic</b>	≤ 30' o > 3h	466	47.60	<b>Ostomia</b>	<b>No</b>	731	73.47
	Entre 30 ' y 3 h	513	52.40		<b>Si</b>	264	26.53
<b>Duració de la cirurgia</b>	< 120'	297	29.85	<b>Ferida</b>	<b>Neta</b>	905	90.95
	≥ 120'	698	70.15		<b>Bruta</b>	90	9.05
<b>Glucèmia 48 hores post-cirurgia</b>	≤ 200 mg/dl	943	96.22	<b>Risc IEQ NNIS</b>	-1/0	519	53.01
	< 200 mg/dl	37	3.78		1/2/3	460	46.99




Tot i que en moltes ocasions la cirurgia colorrectal no cal diferencia-la entre si s'ha utilitzat una tècnica quirúrgica de còlon o de recte, existeixen evidències clíniques que proposen un tracte diferenciat a l'hora d'estudiar el comportament de la infecció en L'espai Quirúrgic. És per aquesta raó que les 995 intervencions quirúrgiques les hem classificat segons si s'ha utilitzat una tècnica quirúrgica de còlon (638 pacients; 64.12%) o de recte (357 pacients; 35.88%).

### **TÈCNICA QUIRÚRGICA CÒLON**

La infecció de l'espai quirúrgic es classifica en infecció incisional (IEQ I), segons si ha estat una infecció superficial o profunda, i en infecció òrgano-cavitària (IEQ OC), altrament. Dels 638 pacients intervinguts per una cirurgia de càncer de còlon, 78 (12.22%) han desenvolupat una infecció incisional i 56 (8.78%) una infecció òrgano-cavitària. Pel que fa a nivell d'hospitals, aquestes es mouen entre el 0% i el 36.36% en el cas de la IEQ I i el 21.42% en el cas de la IEQ OC.

*Gràfic 2. Distribució de les taxes d'infecció incisionals i òrgano-cavitàries en cirurgia de còlon*



Com que tractem la infecció segons si és incisional o òrgano-cavitària, també el conjunt de mesures preventives associades a la infecció incisional són diferents que les mesures preventives associades a la infecció òrgano-cavitària. La taula següent mostra el percentatge de compliment global de cada una de les mesures preventives associades als dos tipus d'infecció en els pacients operats amb tècnica quirúrgica de còlon.

Taula 4. Descripció de l'acompliment de les mesures preventives en cirurgia de Còlon


Tipus d'infecció	Mesures per a la TQ del Còlon	Se'ls ha aplicat		No se'ls ha aplicat	
		N	%	N	%
IEQ Incisional	◆ Dutxa del pacient	631	99	7	1
	◆ Glicèmia preoperatòria. En diabètics es sol·licitarà el nivell de la HbA 1c.	605	95	33	5
	◆ Tall del borboll amb màquina elèctrica d'un sol ús.	554	87	84	13
	◆ No realitzar preparació mecànica del còlon.	362	57	275	43
	◆ Antibiótics profilàctics: de 60 a 30 minuts abans	626	98	12	2
	◆ Canvi de bata al tancament de la laparotomia o ús de bata impermeable.	622	97	16	3
	◆ Canvi de guants al tancament de la laparotomia.	635	99	3	1
	◆ Nova taula i material específic per al tancament de la laparotomia.	604	95	34	5
	◆ Camp sec al tancament de la laparotomia.	626	98	12	2
	◆ Rentat de la ferida quirúrgica abans del tancament cutani.	632	99	6	1
	◆ Mesures per assegurar la normotèrmia.	613	96	25	4
	◆ Si glucèmia > 200 mg/dl, aplicar el protocol de control per a reduir la glucèmia a les 48 hores	561	88	74	12
	<b>Totes les mesures</b>	<b>211</b>	<b>33</b>	<b>426</b>	<b>67</b>
IEQ Òrgano-cavitària	<b>Totes les mesures sense tenir en compte Prep. Mec.</b>	<b>447</b>	<b>70</b>	<b>190</b>	<b>30</b>
	◆ Glicèmia preoperatòria. En diabètics es sol·licitarà el nivell de la HbA 1c.	605	95	33	5
	◆ No realitzar preparació mecànica del còlon.	362	57	275	43
	◆ Mesures per assegurar la normotèrmia.	613	96	25	4
	◆ Si glucèmia > 200 mg/dl, aplicar el protocol de control per a reduir la glucèmia a les 48 hores	561	88	74	12
	<b>Totes les mesures</b>	<b>278</b>	<b>44</b>	<b>359</b>	<b>56</b>

<b>Totes les mesures sense tenir en compte Prep. Mec.</b>	<b>529</b>	<b>83</b>	<b>108</b>	<b>17</b>
---	------------	-----------	------------	-----------

Observem que, per gairebé totes les mesures preventives, l'acompliment es troba per sobre del 80% en ambdós casos, menys per a la mesura corresponent a la no preparació mecànica del còlon. Això és degut a que aquesta mesura no està del tot ben definida i hi ha contradiccions a l'hora de decidir si fer o no fer la preparació mecànica del còlon disminueix o no la taxa d'infecció. Per aquesta raó, a l'hora d'estudiar l'aplicació de totes les mesures preventives, no la tindrem en compte.

D'aquesta manera, observem que l'acompliment global del conjunt de mesures preventives de l'IEQ Incisional s'ha realitzat en 447 pacients (70.17%), mentre que per a l'IEQ Òrgano-cavitària s'ha realitzat a 529 pacients (83.04%).

*Gràfic 3. Distribució del percentatge de compliment de les mesures preventives en cirurgia de còlon*




Segons l'hospital, l'acompliment de les mesures preventives varia entre el 0% i el 100% per les preventives de la IEQ I i entre el 7% i el 100% per les preventives de la IEQ OC. Es pot observar, però, que l'acompliment supera el 80% en els dos casos per la meitat dels hospitals. Un altre fet a destacar és la major variabilitat que s'observa en l'acompliment de les mesures preventives de la IEQ I, comparant-la amb la de l'acompliment de les mesures preventives de la IEQ OC.

Fins aquest punt s'han descrit les taxes d'infecció i els percentatges d'acompliment observats en la globalitat del període d'estudi. La següent gràfica mostra la mitjana de les taxes d'infecció i del percentatge d'acompliment dels hospitals segons el mes d'estudi en el que es troben, és a dir, l'evolució temporal.

Observem que la mitjana de la taxa d'infecció incisional dels hospitals ha variat d'un 12.60% a un 10.17% i la de l'òrgano-cavitària d'un 8.8% fins a un 3.67%. Pel que fa al percentatge d'acompliment de les mesures preventives, la mitjana dels hospitals ha augmentat d'un 56.78% a un 81.33% per les associades a la incisional i d'un 75.35% fins a un 93.33% per les associades a la òrgano-cavitària.

**Gràfic 4.** *Evolució de la infecció i l'acompliment de les mesures preventives en cirurgia de còlon*




### TÈCNICA QUIRÚRGICA RECTE

Dels 357 pacients intervinguts per una cirurgia de càncer de recte, 56 (15.69%) han desenvolupat una infecció incisional i 39 (10.92%) una infecció òrgano-cavitària. Estudiant les taxes d'infecció a nivell dels hospitals, aquestes es mouen entre el 0% i el 50.00% en el cas de la IEQ I i el 33.33% en el cas de la IEQ OC.


El nombre de cirurgies amb el conjunt de mesures preventives associades a la incisional complimentades ha estat de 254 cirurgies (71.14%) i per al conjunt de mesures preventives associades a la òrgano-cavitària de 305 (85.67%).

Si tenim en compte la dispersió dels hospitals respecte aquestes dues dades, observem que hi ha centres que han aplicat el conjunt de mesures preventives, tant per la IEQ I i per la IEQ OC, en totes les seves cirurgies, mentre que hi ha centres a qui no les han aplicat a cap. No obstant, la meitat dels hospitals tenen un compliment superior al 78% en el cas de les mesures preventives de la incisional, y del 89% en les mesures preventives de la òrgano-cavitària.

*Gràfic 5. Distribució de les taxes d'infecció incisionals i òrgano-cavitàries en cirurgia de recte*



Gràfic 6. Distribució del percentatge de compliment de les mesures preventives en cirurgia de recte



Taula 5. Descripció de l'acompliment de les mesures preventives en cirurgia de recte


Tipus d'infecció	Mesures per a la TQ del Recte	Se'ls ha aplicat		No se'ls ha aplicat	
		N	%	N	%
IEQ Incisional	◆ Dutxa del pacient	356	99.7	1	0.03
	◆ Glicèmia preoperatoria. En diabètics es sol·licitarà el nivell de la HbA 1c.	331	93	26	7
	◆ Tall del borboll amb màquina elèctrica d'un sol ús.	312	87	43	12
	◆ Antibiótics profilàctics: de 60 a 30 minuts abans	351	98	6	2
	◆ Canvi de bata al tancament de la laparotomia o ús de bata impermeable.	354	99	3	1
	◆ Canvi de guants al tancament de la laparotomia.	357	100	0	0
	◆ Nova taula i material específic per al tancament de la laparotomia.	346	97	11	3
	◆ Camp sec al tancament de la laparotomia.	356	99.7	1	0.03
	◆ Rentat de la ferida quirúrgica abans del tancament cutani.	352	99	5	1
	◆ Mesures per assegurar la normotèrmia.	348	97	9	2
	◆ Si glucèmia > 200 mg/dl, aplicar el protocol de control per a reduir la	331	93	25	7

	glucèmia a les 48 hores				
	Totes les mesures	269	76	88	24
IEQ Òrgano-cavitària	◆ Glicèmia preoperatòria. En diabètics es sol·licitarà el nivell de la HbA 1c.	331	93	26	7
	◆ Mesures per assegurar la normotèrmia.	348	97	9	2
	◆ Si glucèmia > 200 mg/dl, aplicar el protocol de control per a reduir la glucèmia a les 48 hores	331	93	25	7
	Totes les mesures	305	86	51	14

A l'hora de descriure l'evolució, el següent gràfic representa les mitjanes de les taxes d'infecció i dels percentatges de compliment dels hospitals participants en funció del mes d'estudi.

Observem que la mitjana de la infecció incisional dels hospitals augmenta d'un 17.64% a un 25.00% i la de l'òrgano-cavitària, d'un 9.31% fins a un 14.81%. La mitjana de les mesures preventives augmenta el seu des d'un 57.35% a un 79.63% per les associades de la infecció incisional i des d'un 80.88% fins a un 90.74% per les associades a la infecció òrgano-cavitària.

Gràfic 7. Evolució de la infecció i l'acompliment de les mesures preventives en cirurgia de recte



### 3.1.3 Estimació dels models

Per a intentar respondre a les preguntes sobre la millora de l'acompliment del conjunt de mesures preventives de la IEQ, de la taxa d'infecció a l'espai quirúrgic (incisional i òrgano-cavitària) i sobre l'impacte de l'aplicació de les mesures sobre la IEQ, s'ha proposat l'estimació de models logístics bayesians amb i sense efectes aleatoris.

#### MILLORA DE L'ACOMPLIMENT DE LES MESURES PREVENTIVES

##### Model Logístic Bayesià

$$Y_i \sim \text{Bernoulli}(\theta_i)$$

$$E[Y_i | \beta_0, \beta_1] = \theta_i$$

$$\eta = g(\theta_i) = \log\left(\frac{\theta_i}{1 - \theta_i}\right) = \beta_0 + \beta_1 \text{Mes}_i$$

$$\Pi(\beta_0) = \Pi(\beta_1) = \text{Normal}(0, 0.001)$$

Suposem aquest model on  $Y_i$  és una variable indicadora que pren valor 1 quan al pacient  $i$  se li han aplicat el conjunt de mesures preventives de la IEQ i valor 0 quan no se li han aplicat. La variable  $\text{Mes}_i$  correspon al mes en què ha estat realitzada la intervenció quirúrgica del pacient  $i$ .

Taula 6. Estimació puntual i interval de confiança dels paràmetres del Model Logístic Bayesià per a l'acompliment de les mesures preventives

	Coeficient		Odds Ratio	
	Puntual	IC 95%	Puntual	IC 95%
<b>Intercept</b>	-0.01	-0.35 - 0.33	0.99	0.70 - 1.39
<b>Mes</b>	0.22	0.14 - 0.30	1.24	1.15 - 1.34



### Model Logístic Jeràrquic Bayesià

$$\begin{aligned}
 Y_{ij} &\sim \text{Bernoulli}(\theta_{ij}) \\
 i &= 1, \dots, 23 \text{ hospitals} \\
 j &= 1, \dots, n_i \text{ intervencions quirúrgiques} \\
 E[Y_{ij} | \beta_0, \beta_1, b_i] &= \theta_{ij} \\
 \eta = g(\theta_{ij}) = \log\left(\frac{\theta_{ij}}{1 - \theta_{ij}}\right) &= \beta_0 + \beta_1 \text{Mes}_{ij} + b_i \\
 \Pi(\beta_0) = \Pi(\beta_1) &= \text{Normal}(0, 0.001) \\
 \Pi(b_i) &= \text{Normal}(0, \tau) \\
 \tau &\sim \text{logGamma}(0.01, 0.001)
 \end{aligned}$$

Considerem que  $Y_{ij}$  és una variable indicadora que pren valor 1 quan al pacient  $j$  de l'hospital  $i$  se li han aplicat el conjunt de mesures preventives de la IEQ i valor 0 quan no se li han aplicat. La variable  $\text{Mes}_{ij}$  correspon al mes en què ha estat realitzada la intervenció quirúrgica del pacient  $j$  a l'hospital  $i$ .

En aquest model estem considerant una estructura jeràrquica on els pacients pertanyen a un dels hospitals participants. Aquesta estructura jeràrquica ve definida pels coeficients  $b_i$  que segueixen una distribució *Normal* centrada al 0, però amb una precisió desconeguda que el model estimarà,  $\tau$ . Si aquesta precisió resulta ser molt petita, la probabilitat d'aplicar el conjunt de mesures preventives de la IEQ associada als hospitals no serà la mateixa per a tots els participants; mentre que si la precisió és molt gran, voldrà dir que no hi ha hospitals més probables a l'acompliment d'aquestes mesures.

Taula 7. Estimació puntual i interval de confiança dels paràmetres del Model Logístic Jeràrquic Bayesià per a l'acompliment de les mesures preventives

	Coeficient		Odds Ratio	
	Puntual	IC 95%	Puntual	IC 95%
<b>Intercept</b>	0.37	-1.30 - 2.10	1.44	0.27 - 8.14
<b>Mes</b>	0.23	0.11 - 0.36	1.26	1.12 - 1.43
<b>Precisió (<math>\tau</math>)</b>	0.08	0.07 - 0.17		

A continuació hem estimat un tercer model per conèixer si l'efecte de la millora de l'acompliment de les mesures preventives de la IEQ és heterogeni entre els hospitals participants.

$$\begin{aligned}
 Y_{ij} &\sim \text{Bernoulli}(\theta_{ij}) \\
 i &= 1, \dots, 24 \text{ hospitals} \\
 j &= 1, \dots, n_i \text{ intervencions quirúrgiques} \\
 E[Y_{ij} | \beta_0, b_{0i}, b_{1i}] &= \theta_{ij} \\
 \eta = g(\theta_{ij}) = \log\left(\frac{\theta_{ij}}{1 - \theta_{ij}}\right) &= \beta_0 + b_{0i} + b_{1i} \text{Mes}_{ij} \\
 \Pi(\beta_0) &= \text{Normal}(0, 0.001) \\
 \Pi(b_{0i}) = \Pi(b_{1i}) &= \text{Normal}(0, \tau_k) \\
 \tau_k &\sim \text{logGamma}(0.01, 0.001), \quad \text{on } k = 0, 1
 \end{aligned}$$

Considerem que  $Y_{ij}$  és una variable indicadora que pren valor 1 quan al pacient  $j$  de l'hospital  $i$  se li han aplicat el conjunt de mesures preventives de la IEQ i valor 0 quan no se li han aplicat. La variable  $\text{Mes}_{ij}$  correspon al mes en què ha estat realitzada la intervenció quirúrgica del pacient  $j$  a l'hospital  $i$ .

En aquest model estem considerant una estructura jeràrquica on els pacients pertanyen a un dels hospitals participants. Aquesta estructura jeràrquica ve definida pels coeficients  $b_{0i}$  que segueixen una distribució *Normal* centrada al 0, però amb una precisió desconeguda que el model estimarà,  $\tau_0$ .  $b_{1i}$  representa de la millora de l'acompliment de les mesures preventives en l'hospital  $i$ .

*Taula 8. Estimació puntual i interval de confiança dels paràmetres del Model Logístic Jeràrquic Bayesià amb temps com a efecte aleatori per a l'acompliment de les mesures preventives*

	<b>Coefficient</b>		<b>Odds Ratio</b>	
	Puntual	IC 95%	Puntual	IC 95%
<b>Intercept</b>	-0.08	-0.56 - 0.40	0.92	0.57 - 1.49
<b>Precisió (<math>\tau_0</math>)</b>	18530	1259 – 6679		
<b>Precisió (<math>\tau_1</math>)</b>	0.53	0.17 – 1.23		

## MILLORA DE LA INFECCIÓ EN L'ESPai QUIRÚRGIC INCISIONAL I L'IMPACTE DE LES MESURES EN CIRURGIA DE CÒLON LA SEVA RELACIÓ AMB L'ACOMPLIMENT DE LES MESURES PREVENTIVES

### Model Logístic Bayesià

$$\begin{aligned} Y_i &\sim \text{Bernoulli}(\theta_i) \\ E[Y_i | \beta_0, \beta_1, \dots, \beta_p] &= \theta_i \\ \eta = g(\theta_i) = \log\left(\frac{\theta_i}{1 - \theta_i}\right) &= \beta_0 + \sum_{k=1}^p \beta_k X_{ki} \\ \Pi(\beta_0) = \Pi(\beta_k) &= \text{Normal}(0, 0.001), k = 1, \dots, p \end{aligned}$$

Suposem aquest model on  $Y_i$  és una variable indicadora que pren valor 1 quan en el pacient  $i$  ha desenvolupat una IEQ Incisional i valor 0 quan no l'ha desenvolupat.

Com que la IEQ és una variable resposta a la intervenció quirúrgica d'un pacient, és coherent pensar que poden existir efectes associats a les característiques d'aquests pacients i també a les característiques de la intervenció. És per aquest motiu que per avaluar la millora i poder conèixer l'existència d'una relació entre l'aplicació de les mesures preventives i la taxa d'infecció, haurem d'ajustar el model per aquelles variables relacionades amb la tipologia de la intervenció i del pacient que puguin afectar al desenvolupament de la IEQ.

El conjunt de variables  $X_{ki}$  són aquelles relacionades amb les característiques del pacient  $i$  i la seva intervenció quirúrgica, juntament amb el mes en què s'ha practicat aquesta intervenció i si se li han aplicat el conjunt de mesures preventives.

**Ajust per les variables de pacient.** De tot el conjunt de variables recollides en els qüestionaris, a partir del DIC, del CPO i de l'interval de confiança del 95% per al coeficient  $\beta_k$  (interval de valors de la distribució a posteriori del coeficient  $\beta_k$  entre el percentil 0.025 i el 0.975) hem seleccionat aquelles variables que podrien tenir alguna relació amb la infecció. Aquestes variables, introduïdes consecutivament al model, han estat: el sexe, la glucèmia perioperatòria i l'índex NNIS.

Taula 9. Variables demogràfiques, clíniques, perioperatòries i operatòries significatives del Model Logístic Bayesià per a la infecció incisional en cirurgia de còlon

◆ <b>Model nul</b>	DIC	475.90
	CPO	0.3729683
◆ <b>Sexe</b> (primera variable introduïda)	DIC	473.49
	CPO	0.3711003
◆ <b>Glucèmia perioperatòria</b> (segona variable introduïda)	DIC	471.8034
	CPO	0.369885
◆ <b>Índex NNIS</b> (tercera variable introduïda)	DIC	470.9787
	CPO	0.3692763

Un cop ajustada la IEQ en funció del sexe, l' Índex NNIS i la glucèmia perioperatòria, afegim al model la variable indicadora de l'acompliment de les mesures preventives. Com hem observat que l'acompliment de les mesures preventives augmentava al llarg dels mesos en que s'ha fet l'estudi, també incorporarem al model la variable mes de l'estudi i la interacció entre el mes de l'estudi i l'acompliment de les mesures.

Primer observem el model amb les mesures preventives i el mes de l'estudi com a variables explicatives. A l'introduir la variable indicadora de l'acompliment de les mesures el DIC i el CPO disminueixen (465.3481 i 0.3649773 respectivament). El mateix passa amb la introducció de la variable mes d'estudi (DIC = 464.9496 i CPO = 0.3647294). Si ara considerem la interacció entre l'acompliment de les mesures preventives i el mes de l'estudi, el DIC i el CPO també milloren (463.7986 i 0.3637861).

Per acabar amb la construcció d'aquest primer model, ens plantegem la introducció al model de la interacció entre la variable Index NNIS (risc d'infecció) i l'acompliment de les mesures preventives. S'ha observat que un 47% dels pacients a qui se'ls ha aplicat el conjunt de mesures preventives tenien un risc alt d'infectar-se, mentre que el 67% dels pacients a qui no se'ls ha aplicat les mesures tenien un risc baix d'infecció. La introducció d'aquesta interacció no disminueix el DIC (464.3944) ni el CPO (0.3643623) però el seu efecte pot tenir una tendència interessant.

### Model Logístic Jeràrquic Bayesià

$$\begin{aligned}
 &Y_{ij} \sim \text{Bernoulli}(\theta_{ij}) \\
 &i = 1, \dots, 23 \text{ hospitals} \\
 &j = 1, \dots, n_i \text{ intervencions quirúrgiques} \\
 &E[Y_{ij} | \beta_0, \beta_k, b_i] = \theta_{ij} \\
 &\eta = g(\theta_{ij}) = \log\left(\frac{\theta_{ij}}{1 - \theta_{ij}}\right) = \beta_0 + \sum_{k=1}^p \beta_k X_{kij} + b_i \\
 &\Pi(\beta_0) = \Pi(\beta_k) = \text{Normal}(0, 0.001), k = 1, \dots, p \\
 &\Pi(b_i) = \text{Normal}(0, \tau) \\
 &\tau \sim \text{logGamma}(0.01, 0.001)
 \end{aligned}$$

Considerem que  $Y_{ij}$  és una variable indicadora que pren valor 1 quan al pacient  $j$  de l'hospital  $i$  s'ha infectat i valor 0 quan no. El conjunt de variables  $X_{kij}$  són aquelles relacionades amb les característiques del pacient  $j$  de l'hospital  $i$  i la seva intervenció quirúrgica, juntament amb el mes en què s'ha practicat aquesta intervenció i si se li han aplicat el conjunt de mesures preventives.

En aquest model estem considerant una estructura jeràrquica on els pacients pertanyen a un dels hospitals participants. Aquesta estructura jeràrquica ve definida pels coeficients  $b_i$  que segueixen una distribució *Normal* centrada al 0, però amb una precisió desconeguda que el model estimarà,  $\tau$ . Si aquesta precisió resulta ser molt petita, la probabilitat d'infecció associada als hospitals no serà la mateixa per a tots els participants; mentre que si la precisió és molt gran, voldrà dir que no hi ha diferències respecte la probabilitat de desenvolupar una IEQ.

Primer introduïm l'efecte aleatori hospital en el model nul, i obtenim una estimació puntual de la precisió igual a 18791.43. El DIC i el CPO per aquest model són 475.8909 i 0.372961 respectivament. Seguint el mateix procediment que en el model anterior, obtenim que les variables amb un efecte significatiu són el sexe, la glucèmia perioperatòria i el risc NNIS.

*Taula 10. Variables demogràfiques, clíniques, perioperatòries i operatòries significatives del Model Logístic Jeràrquic Bayesià per a la infecció incisional en cirurgia de còlon*

◆ <b>Model nul</b>	DIC	475.8909
	CPO	0.372961
◆ <b>Sexe</b> (primera variable introduïda)	DIC	473.4858
	CPO	0.3710933
◆ <b>Glucèmia perioperatòria</b> (segona variable introduïda)	DIC	471.7943
	CPO	0.3698779
◆ <b>Índex NNIS</b> (tercera variable introduïda)	DIC	470.9697
	CPO	0.3692694

La precisió dels coeficients dels hospitals per aquest model ajustat és de 18802.82.

Al model ajustat anterior, li afegim la variable compliment de les mesures, la variable mes de l'estudi i la seva interacció. Provem d'ajustar, també, amb la interacció de l'acompliment de les mesures i el risc NNIS.

*Taula 11. Acompliment de les mesures preventives i Mes d'estudi en el Model Logístic Jeràrquic Bayesià per a la infecció incisional en cirurgia de còlon*

◆ <b>Mesures Preventives</b>	DIC	465.3405
	CPO	0.3649714
◆ <b>Mes de l'estudi</b>	DIC	464.943
	CPO	0.3647243
◆ <b>Interacció Mes de l'estudi i Mesures Preventives</b>	DIC	463.7931
	CPO	0.3637818
◆ <b>Interacció Mesures Preventives i NNIS</b>	DIC	464.3898
	CPO	0.364359

La precisió associada a l'efecte hospital és 18825.17.

## MILLORA DE LA INFECCIÓ EN L'ESPAI QUIRÚRGIC ÒRGANO-CAVITÀRIA I L'IMPACTE DE LES MESURES EN CIRURGIA DE CÒLON

### Model Logístic Bayesià

$$\begin{aligned} Y_i &\sim \text{Bernoulli}(\theta_i) \\ E[Y_i | \beta_0, \beta_1, \dots, \beta_p] &= \theta_i \\ \eta = g(\theta_i) = \log\left(\frac{\theta_i}{1 - \theta_i}\right) &= \beta_0 + \sum_{k=1}^p \beta_k X_{ki} \\ \Pi(\beta_0) = \Pi(\beta_k) &= \text{Normal}(0, 0.001), k = 1, \dots, p \end{aligned}$$

Suposem aquest model on  $Y_i$  és una variable indicadora que pren valor 1 quan en el pacient  $i$  ha desenvolupat una IEQ Òrgano-cavitària i valor 0 quan no l'ha desenvolupat.

Com que la IEQ és una variable resposta a la intervenció quirúrgica d'un pacient, és coherent pensar que poden existir efectes associats a les característiques d'aquests pacients i també a les característiques de la intervenció. És per aquest motiu que per avaluar la millora i poder conèixer l'existència d'una relació entre l'aplicació de les mesures preventives i la taxa d'infecció, haurem d'ajustar el model per aquelles variables relacionades amb la tipologia de la intervenció i del pacient que puguin afectar al desenvolupament de la IEQ.

El conjunt de variables  $X_{ki}$  són aquelles relacionades amb les característiques del pacient  $i$  i la seva intervenció quirúrgica, juntament amb el mes en què s'ha practicat aquesta intervenció i si se li han aplicat el conjunt de mesures preventives.

**Ajust per les variables de pacient i de la intervenció.** De tot el conjunt de variables recollides en els qüestionaris, a partir del DIC, del CPO i de l'interval de confiança del 95% per al coeficient  $\beta_k$  (interval de valors de la distribució a posteriori del coeficient  $\beta_k$  entre el percentil 0.025 i el 0.975) hem seleccionat aquelles variables que podrien tenir alguna relació amb la infecció. Aquestes variables, introduïdes consecutivament al model, han estat: l'ASA, el tipus de cirurgia, el cirurgià que ha realitzat la intervenció, l'hora d'administració de l'antibiòtic i si hi ha hagut transfusions perioperatòries.

Taula 12. Variables demogràfiques, clíniques, perioperatòries i operatòries significatives del Model Logístic Bayesià per a la infecció òrgano-cavitària en cirurgia de còlon

◆ <b>Model nul</b>	DIC	381.4238
	CPO	0.2989292
◆ <b>ASA</b> (primera variable introduïda)	DIC	378.5573
	CPO	0.2967053
◆ <b>Tipus de Cirurgia</b> (segona variable introduïda)	DIC	372.4959
	CPO	0.2919874
◆ <b>Cirurgia</b> (tercera variable introduïda)	DIC	370.9175
	CPO	0.2907948
◆ <b>Hora de l'administració de l'antibiòtic</b> (quarta variable introduïda)	DIC	368.1929
	CPO	0.2887844
◆ <b>Transfusions Perioperatòries</b> (cinquena variable introduïda)	DIC	354.6362
	CPO	0.2782659

Un cop ajustada la IEQ en funció de les variables relacionades amb el pacient i el tipus de cirurgia, afegim al model la variable indicadora de l'acompliment de les mesures preventives. Com hem observat que l'acompliment de les mesures preventives augmentava al llarg dels mesos en que s'ha fet l'estudi, també incorporarem al model la variable mes de l'estudi. La interacció entre el mes de l'estudi i l'acompliment de les mesures, en aquest model, no ha resultat significativa.

A l'introduir la variable indicadora de l'acompliment de les mesures el DIC i el CPO disminueixen (352.9242 i 0.2769323 respectivament). El mateix passa amb la introducció de la variable mes d'estudi (DIC = 350.2249 i CPO = 0.2748926). Si ara considerem la interacció entre l'acompliment de les mesures preventives i el mes de l'estudi, observem que el DIC i el CPO no milloren (352.0036 i 0.2765253).



### Model Logístic Jeràrquic Bayesià

$$\begin{aligned}
 &Y_{ij} \sim \text{Bernoulli}(\theta_{ij}) \\
 &i = 1, \dots, 23 \text{ hospitals} \\
 &j = 1, \dots, n_i \text{ intervencions quirúrgiques} \\
 &E[Y_{ij} | \beta_0, \beta_k, b_i] = \theta_{ij} \\
 &\eta = g(\theta_{ij}) = \log\left(\frac{\theta_{ij}}{1 - \theta_{ij}}\right) = \beta_0 + \sum_{k=1}^p \beta_k X_{kij} + b_i \\
 &\Pi(\beta_0) = \Pi(\beta_k) = \text{Normal}(0, 0.001), k = 1, \dots, p \\
 &\Pi(b_i) = \text{Normal}(0, \tau) \\
 &\tau \sim \text{logGamma}(0.01, 0.001)
 \end{aligned}$$

Considerem que  $Y_{ij}$  és una variable indicadora que pren valor 1 quan al pacient  $j$  de l'hospital  $i$  s'ha infectat i valor 0 quan no. El conjunt de variables  $X_{kij}$  són aquelles relacionades amb les característiques del pacient  $j$  de l'hospital  $i$  i la seva intervenció quirúrgica, juntament amb el mes en què s'ha practicat aquesta intervenció i si se li han aplicat el conjunt de mesures preventives.

En aquest model estem considerant una estructura jeràrquica on els pacients pertanyen a un dels hospitals participants. Aquesta estructura jeràrquica ve definida pels coeficients  $b_i$  que segueixen una distribució *Normal* centrada al 0, però amb una precisió desconeguda que el model estimarà,  $\tau$ . Si aquesta precisió resulta ser molt petita, la probabilitat d'infecció associada als hospitals no serà la mateixa per a tots els participants; mentre que si la precisió és molt gran, voldrà dir que no hi ha hospitals més probables a la infecció.

Primer introduïm l'efecte aleatori hospital en el model nul, i obtenim una estimació puntual de la precisió igual a 18572.52. El DIC i el CPO per aquest model són 381.4207 i 0.2989267 respectivament. Seguint el mateix procediment que en el model anterior, obtenim que les variables amb un efecte significatiu són l'ASA, el tipus de cirurgia, el cirurgià que ha realitzat la intervenció, l'hora d'administració de l'antibiòtic i si hi ha hagut transfusions perioperatòries.

Taula 13. Variables demogràfiques, clíniques, perioperatòries i operatòries significatives del Model Logístic Jeràrquic Bayesià per a la infecció òrgano-cavitària en cirurgia de còlon

◆ <b>Model nul</b>	DIC	381.4207
	CPO	0.2989267
◆ <b>ASA</b> (primera variable introduïda)	DIC	378.5544
	CPO	0.2967032
◆ <b>Tipus de Cirurgia</b> (segona variable introduïda)	DIC	372.4949
	CPO	0.2919864
◆ <b>Cirurgia</b> (tercera variable introduïda)	DIC	370.9155
	CPO	0.2907932
◆ <b>Hora de l'administració de l'antibiòtic</b> (quarta variable introduïda)	DIC	368.1973
	CPO	0.2887846
◆ <b>Transfusions Perioperatòries</b> (cinquena variable introduïda)	DIC	354.6387
	CPO	0.2782681

La precisió dels coeficients dels hospitals per aquest model ajustat és de 18593.96.

Al model ajustat anterior, li afegim la variable acompliment de les mesures, la variable mes de l'estudi i la seva interacció, aquesta última no la considerarem al no millorar el DIC ni el CPO.

Taula 14. Acompliment de les mesures preventives i Mes d'estudi en el Model Logístic Jeràrquic Bayesià per a la infecció òrgano-cavitària en cirurgia de còlon

◆ <b>Mesures Preventives</b>	DIC	352.9278
	CPO	0.2769354
◆ <b>Mes de l'estudi</b>	DIC	350.2254
	CPO	0.2748927
◆ <b>Interacció Mes de l'estudi i Mesures Preventives</b>	DIC	352.0067
	CPO	0.276527

La precisió associada a l'efecte hospital és 18596.51.

## MILLORA DE LA INFECCIÓ EN L'ESPAI QUIRÚRGIC INCISIONAL I L'IMPACTE DE LES MESURES EN CIRURGIA DE RECTE

### Model Logístic Bayesià

$$\begin{aligned} Y_i &\sim \text{Bernoulli}(\theta_i) \\ E[Y_i | \beta_0, \beta_1, \dots, \beta_p] &= \theta_i \\ \eta = g(\theta_i) = \log\left(\frac{\theta_i}{1 - \theta_i}\right) &= \beta_0 + \sum_{k=1}^p \beta_k X_{ki} \\ \Pi(\beta_0) = \Pi(\beta_k) &= \text{Normal}(0, 0.001), k = 1, \dots, p \end{aligned}$$

Suposem aquest model on  $Y_i$  és una variable indicadora que pren valor 1 quan en el pacient  $i$  ha desenvolupat una IEQ Incisional i valor 0 quan no l'ha desenvolupat.

Com que la IEQ és una variable resposta a la intervenció quirúrgica d'un pacient, és coherent pensar que poden existir efectes associats a les característiques d'aquests pacients i també a les característiques de la intervenció. És per aquest motiu que per avaluar la millora i poder conèixer l'existència d'una relació entre l'aplicació de les mesures preventives i la taxa d'infecció, haurem d'ajustar el model per aquelles variables relacionades amb la tipologia de la intervenció i del pacient que puguin afectar al desenvolupament de la IEQ.

El conjunt de variables  $X_{ki}$  són aquelles relacionades amb les característiques del pacient  $i$  i la seva intervenció quirúrgica, juntament amb el mes en què s'ha practicat aquesta intervenció i si se li han aplicat el conjunt de mesures preventives.

**Ajust per les variables de pacient.** De tot el conjunt de variables recollides en els qüestionaris, a partir del DIC, del CPO i de l'interval de confiança del 95% per al coeficient  $\beta_k$  (interval de valors de la distribució a posteriori del coeficient  $\beta_k$  entre el percentil 0.025 i el 0.975) hem seleccionat aquelles variables que podrien tenir alguna relació amb la infecció. Aquestes variables, introduïdes consecutivament al model, han estat: l'edat, índex NNIS, la hipertensió, l'índex de Charlson i l'anastomosi.

Taula 15. Variables demogràfiques, clíniques, perioperatòries i operatòries significatives del Model Logístic Bayesià per a la infecció incisional en cirurgia de recte

◆ <b>Model nul</b>	DIC	312.1783
	CPO	0.4372395
◆ <b>Edat</b> (primera variable introduïda)	DIC	311.824
	CPO	0.4370003
◆ <b>Índex NNIS</b> (segona variable introduïda)	DIC	308.7082
	CPO	0.4326181
◆ <b>Hipertensió</b> (tercera variable introduïda)	DIC	305.2774
	CPO	0.4279017
◆ <b>Índex de Charlson</b> (quarta variable introduïda)	DIC	302.1869
	CPO	0.4235428
◆ <b>Anastomosi</b> (cinquena variable introduïda)	DIC	280.1704
	CPO	0.3927966

Un cop ajustada la IEQ en funció de les variables relacionades amb la tipologia de pacient i de cirurgia, afegim al model la variable indicadora de l'acompliment de les mesures preventives. Com hem observat que l'acompliment de les mesures preventives augmentava al llarg dels mesos en que s'ha fet l'estudi, també incorporarem al model la variable mes de l'estudi i la interacció entre el mes de l'estudi i l'acompliment de les mesures.

Primer observem el model amb les mesures preventives i el mes de l'estudi com a variables explicatives. A l'introduir la variable indicadora de l'acompliment de les mesures el DIC i el CPO augmenten (281.8993 i 0. 0.395424 respectivament). El mateix passa amb la introducció de la variable mes d'estudi (DIC = 281.7065 i CPO = 0.3952505). Però si ara considerem la interacció entre l'acompliment de les mesures preventives i el mes de l'estudi, el DIC i el CPO milloren (279.3837 i 0.3926959).

### Model Logístic Jeràrquic Bayesià

$$\begin{aligned}
 Y_{ij} &\sim \text{Bernoulli}(\theta_{ij}) \\
 i &= 1, \dots, 23 \text{ hospitals} \\
 j &= 1, \dots, n_i \text{ intervencions quirúrgiques} \\
 E[Y_{ij} | \beta_0, \beta_k, b_i] &= \theta_{ij} \\
 \eta = g(\theta_{ij}) = \log\left(\frac{\theta_{ij}}{1 - \theta_{ij}}\right) &= \beta_0 + \sum_{k=1}^p \beta_k X_{kij} + b_i \\
 \Pi(\beta_0) = \Pi(\beta_k) &= \text{Normal}(0, 0.001), k = 1, \dots, p \\
 \Pi(b_i) &= \text{Normal}(0, \tau) \\
 \tau &\sim \text{logGamma}(0.01, 0.001)
 \end{aligned}$$

Considerem que  $Y_{ij}$  és una variable indicadora que pren valor 1 quan al pacient  $j$  de l'hospital  $i$  s'ha infectat i valor 0 quan no. El conjunt de variables  $X_{kij}$  són aquelles relacionades amb les característiques del pacient  $j$  de l'hospital  $i$  i la seva intervenció quirúrgica, juntament amb el mes en què s'ha practicat aquesta intervenció i si se li han aplicat el conjunt de mesures preventives.

En aquest model estem considerant una estructura jeràrquica on els pacients pertanyen a un dels hospitals participants. Aquesta estructura jeràrquica ve definida pels coeficients  $b_i$  que segueixen una distribució *Normal* centrada al 0, però amb una precisió desconeguda que el model estimarà,  $\tau$ . Si aquesta precisió resulta ser molt petita, la probabilitat d'infecció associada als hospitals no serà la mateixa per a tots els participants; mentre que si la precisió és molt gran, voldrà dir que no hi ha hospitals on és més probable desenvolupar una infecció.

Primer introduïm l'efecte aleatori hospital en el model nul, i obtenim una estimació puntual de la precisió igual a 18561.78. El DIC i el CPO per aquest model són 312.1776 i 0.4372384 respectivament. Seguint el mateix procediment que en el model anterior, obtenim que les variables amb un efecte significatiu són l'edat, índex NNIS, la hipertensió, l'índex de Charlson i l'anastomosi.

*Taula 16. Variables demogràfiques, clíniques, perioperatòries i operatòries significatives del Model Logístic Jeràrquic Bayesià per a la infecció incisional en cirurgia de recte*

◆ <b>Model nul</b>	DIC	312.1776
	CPO	0.4372384
◆ <b>Edat</b> <i>(primera variable introduïda)</i>	DIC	311.8235
	CPO	0.4369996
◆ <b>Índex NNIS</b> <i>(segona variable introduïda)</i>	DIC	308.7075
	CPO	0.4326175
◆ <b>Hipertensió</b> <i>(tercera variable introduïda)</i>	DIC	305.2761
	CPO	0.4279005
◆ <b>Índex de Charlson</b> <i>(quarta variable introduïda)</i>	DIC	302.1864
	CPO	0.423542
◆ <b>Anastomosi</b> <i>(cinquena variable introduïda)</i>	DIC	280.1673
	CPO	0.3927926

La precisió dels coeficients dels hospitals per aquest model ajustat és de 18552.33.

Al model ajustat anterior, li afegim la variable acompliment de les mesures, la variable mes de l'estudi i la seva interacció.

*Taula 17. Acompliment de les mesures preventives i Mes d'estudi en el Model Logístic Jeràrquic Bayesià per a la infecció incisional en cirurgia de recte*

◆ <b>Mesures Preventives</b>	DIC	281.8971
	CPO	0.3954212
◆ <b>Mes de l'estudi</b>	DIC	281.7034
	CPO	0.3952471
◆ <b>Interacció Mes de l'estudi i Mesures Preventives</b>	DIC	279.3789
	CPO	0.39269

La precisió associada a l'efecte hospital és 18581.35.

## MILLORA DE LA INFECCIÓ EN L'ESPAI QUIRÚRGIC ÒRGANO-CAVITÀRIA I L'IMPACTE DE LES MRESURES EN CIRURGIA DE RECTE

### Model Logístic Bayesià

$$\begin{aligned} Y_i &\sim \text{Bernoulli}(\theta_i) \\ E[Y_i | \beta_0, \beta_1, \dots, \beta_p] &= \theta_i \\ \eta = g(\theta_i) = \log\left(\frac{\theta_i}{1 - \theta_i}\right) &= \beta_0 + \sum_{k=1}^p \beta_k X_{ki} \\ \Pi(\beta_0) = \Pi(\beta_{ik}) &= \text{Normal}(0, 0.001), k = 1, \dots, p \end{aligned}$$

Suposem aquest model on  $Y_i$  és una variable indicadora que pren valor 1 quan en el pacient  $i$  ha desenvolupat una IEQ Òrgano-cavitària i valor 0 quan no l'ha desenvolupat.

Com que la IEQ és una variable resposta a la intervenció quirúrgica d'un pacient, és coherent pensar que poden existir efectes associats a les característiques d'aquests pacients i també a les característiques de la intervenció. És per aquest motiu que per avaluar la millora i poder conèixer l'existència d'una relació entre l'aplicació de les mesures preventives i la taxa d'infecció, haurem d'ajustar el model per aquelles variables relacionades amb la tipologia de la intervenció i del pacient que puguin afectar al desenvolupament de la IEQ.

El conjunt de variables  $X_{ki}$  són aquelles relacionades amb les característiques del pacient  $i$  i la seva intervenció quirúrgica, juntament amb el mes en què s'ha practicat aquesta intervenció i si se li han aplicat el conjunt de mesures preventives.

**Ajust per les variables de pacient i de la intervenció.** De tot el conjunt de variables recollides en els qüestionaris, a partir del DIC, del CPO i de l'interval de confiança del 95% per al coeficient  $\beta_k$  (interval de valors de la distribució a posteriori del coeficient  $\beta_k$  entre el percentil 0.025 i el 0.975) hem seleccionat aquelles variables que podrien tenir alguna relació amb la infecció. Seguint aquest procediment no hem trobat cap variable relacionada amb la tipologia del pacient i de la intervenció que pugui explicar la probabilitat de la infecció OC en cirurgia de recte.

*Taula 18. Variables demogràfiques, clíniques, perioperatòries i operatòries significatives del Model Logístic Bayesià per a la infecció òrgano-cavitària en cirurgia de recte*

◆ <b>Model nul</b>	DIC	248.2737
	CPO	0.3477427

En aquest punt, provem d'introduir al model la variable indicadora de l'acompliment de les mesures preventives. Com hem observat que l'acompliment de les mesures preventives augmentava al llarg dels mesos en que s'ha fet l'estudi, també incorporarem al model la variable mes de l'estudi i la seva interacció-

A l'introduir la variable indicadora de l'acompliment de les mesures el DIC i el CPO augmenten (250.1733 i 0.3504748 respectivament). El mateix passa amb la introducció de la variable mes d'estudi (DIC = 249.8648 i CPO = 0.3501387). Si ara considerem la interacció entre l'acompliment de les mesures preventives i el mes de l'estudi, observem que el DIC i el CPO tampoc milloren (253.3366 i 0.3557244).

**De les variables que s'han recollit en el qüestionari, en cap s'ha pogut trobar una relació significativa entre la infecció OC en cirurgia de recte.**

#### Model Logístic Jeràrquic Bayesià

$$\begin{aligned}
 &Y_{ij} \sim \text{Bernoulli}(\theta_{ij}) \\
 &i = 1, \dots, 23 \text{ hospitals} \\
 &j = 1, \dots, n_i \text{ intervencions quirúrgiques} \\
 &E[Y_{ij} | \beta_0, \beta_k, b_i] = \theta_{ij} \\
 &\eta = g(\theta_{ij}) = \log\left(\frac{\theta_{ij}}{1 - \theta_{ij}}\right) = \beta_0 + \sum_{k=1}^p \beta_k X_{kij} + b_i \\
 &\Pi(\beta_0) = \Pi(\beta_k) = \text{Normal}(0, 0.001), k = 1, \dots, p \\
 &\Pi(b_i) = \text{Normal}(0, \tau) \\
 &\tau \sim \text{logGamma}(0.01, 0.001)
 \end{aligned}$$



Considerem que  $Y_{ij}$  és una variable indicadora que pren valor 1 quan al pacient  $j$  de l'hospital  $i$  s'ha infectat i valor 0 quan no. El conjunt de variables  $X_{kij}$  són aquelles relacionades amb les característiques del pacient  $j$  de l'hospital  $i$  i la seva intervenció quirúrgica, juntament amb el mes en què s'ha practicat aquesta intervenció i si se li han aplicat el conjunt de mesures preventives.

En aquest model estem considerant una estructura jeràrquica on els pacients pertanyen a un dels hospitals participants. Aquesta estructura jeràrquica ve definida pels coeficients  $b_i$  que segueixen una distribució *Normal* centrada al 0, però amb una precisió desconeguda que el model estimarà,  $\tau$ . Si aquesta precisió resulta ser molt petita, la probabilitat d'infecció associada als hospitals no serà la mateixa per a tots els participants; mentre que si la precisió és molt gran, voldrà dir que no hi ha hospitals més probables a la infecció.

Primer introduïm l'efecte aleatori hospital en el model nul, i obtenim una estimació puntual de la precisió igual a 18542.34. El DIC i el CPO per aquest model són 248.2713 i 0.3477392 respectivament. Seguint el mateix procediment que en el model anterior, tampoc obtenim que variable amb un efecte significatiu.

Al model ajustat anterior, li afegim la variable acompliment de les mesures, la variable mes de l'estudi i la seva interacció.

*Taula 19. Acompliment de les mesures preventives i Mes d'estudi en el Model Logístic Jeràrquic Bayesià per a la infecció òrgano-cavitària en cirurgia de recte*

◆ Mesures Preventives	DIC	250.1708
	CPO	0.350471
◆ Mes de l'estudi	DIC	249.862
	CPO	0.3501348
◆ Interacció Mes de l'estudi i Mesures Preventives	DIC	253.3338
	CPO	0.355721

### 3.1.4 Selecció dels models

Un cop estimats els possibles models candidats per a explicar cada un dels problemes plantejats, en aquesta secció seleccionarem el millor.

#### **MILLORA DE L'ACOMPLIMENT DE LES MESURES PREVENTIVES**


Recordem que per a explicar si hi ha hagut una millora de l'acompliment de les mesures preventives hem ajustat tres models logístics bayesians, tenint i sense tenir en compte els efectes aleatoris dels hospitals. A la següent taula s'especifica, per cada un dels models, el valor obtingut del DIC i del CPO.

*Taula 20. Criteris de selecció entre els models plantejats per avaluar la millora de l'acompliment de les mesures preventives*

<b>Model</b>	<b>DIC</b>	<b>CPO</b>
<b>Model 1. Efectes Fixos de la millora de l'acompliment de les mesures</b>	748.5652	0.5876045
<b>Model 2. Efectes Aleatoris de l'acompliment dels Hospitals</b>	390.5462	0.3005891
<b>Model 3. Efectes Aleatoris de la millora dels hospitals</b>	---	0.4898487


Tenint en compte el criteri que com menor sigui el número del DIC i del CPO, millor és el model, a partir de la taula anterior, seleccionàriem el Model 2.

Gràfic 8. *Efectes aleatoris dels hospitals associats al compliment de les mesures preventives estimats a partir del model 2.*




En aquest gràfic podem observar com la distribució de l'acompliment de les mesures preventives no és homogeni entre els hospitals participants, per tant, és lògic tenir en compte en l'ajust del model l'efecte aleatori hospital.

Gràfic 9. *Efectes aleatoris dels hospitals associats al compliment de les mesures preventives estimats a partir del model 3.*



En aquest gràfic podem observar com la distribució de l'acompliment de les mesures preventives a l'inici del projecte era bastant homogeni entre els hospitals participants.

Gràfic 10. *Efectes aleatoris de la millora del compliment de les mesures preventives dels hospitals estimats a partir del model 2.*



En aquest gràfic podem observar com la distribució de la millora de l'acompliment de les mesures preventives no és homogeni entre els hospitals participants.

Aquests dos últims gràfics mostren que l'heterogeneïtat en l'acompliment de les mesures preventives entre els hospitals participants és deguda a l'efecte que ha tingut el temps en l'increment d'aquest acompliment, ja que, inicialment, tots els hospitals partien del mateix punt.

### **MILLORA DE LA INFECCIÓ EN L'ESPAI QUIRÚRGIC INCISIONAL I L'IMPACTE DE LES MESURES EN CIRURGIA DE CÒLON**

Per escollir entre els dos models estimats, el model logístic bayesià sense efectes aleatoris i el model logístic jeràrquic bayesià, ens fixem en la utilitat, o no, d'afegir al model logístic bayesià

l'efecte dels hospitals. Aquesta decisió la prenem fixant-nos amb la precisió associada a l'efecte hospital del model jeràrquic que, com ja hem comentat, és la indicadora de si existeix variabilitat en les probabilitats d'infecció dels hospitals participants. La precisió ha estat de 18825.17, això vol dir que no hi ha hospitals que augmentin la probabilitat d'infecció, un cop aquesta ajustada per les mesures preventives i per les variables de tipologia de pacient i d'intervenció quirúrgica.

El gràfic següent, on es mostren els efectes dels hospitals, és la manera gràfica de mostrar aquesta manca de variabilitat entre hospitals. Observem que els seus efectes estan centrats al 0 i que no n'hi ha cap de significatiu.

Gràfic 11. *Efectes aleatoris dels hospitals associats a la infecció incisional en cirurgia de còlon estimats a partir del model 2.*



Taula 21. *Criteris de selecció entre els models plantejats per avaluar la millora de la infecció incisional i l'impacte de les mesures preventives en cirurgia de còlon*

Model	DIC	CPO
<b>Model 1. Model amb efectes fixos</b>	464.3944	0.3643623
<b>Model 2. Model amb efectes fixos i aleatoris</b>	464.3898	0.364359


Observem que el model d'efectes fixos té major DIC i CPO que el model d'efectes aleatoris. No obstant, seguint amb el raonament anterior, seleccionem el model 1, d'efectes fixos.

### **MILLORA DE LA INFECCIÓ EN L'ESPAI QUIRÚRGIC ÒRGANO-CAVITÀRIA I L'IMPACTE DE LES MESURES EN CIRURGIA DE CÒLON**

Per escollir entre els dos models estimats, el model logístic bayesià sense efectes aleatoris i el model logístic jeràrquic bayesià, ens fixem en la utilitat, o no, d'afegir al model logístic bayesià l'efecte dels hospitals. Aquesta decisió la prenem fixant-nos amb la precisió associada a l'efecte hospital del model jeràrquic que, com ja hem comentat, és la indicadora de si existeix variabilitat en les probabilitats d'infecció dels hospitals participant. La precisió ha estat de 18596.51, aquest és un valor gran que vol dir que no hi ha diferències entre els hospitals participants pel que fa a la probabilitat d'infecció, un cop aquesta ajustada per les mesures preventives i per les variables de tipologia de pacient i d'intervenció quirúrgica.

El gràfic següent, on es mostren els efectes dels hospitals, és la manera gràfica de mostrar aquesta manca de variabilitat entre hospitals. Observem que els seus efectes estan centrats al 0 i que no n'hi ha cap de significatiu.

*Gràfic 12. Efectes aleatoris dels hospitals associats a la infecció òrgano-cavitària en cirurgia de còlon estimats a partir del model 2.*



A la següent taula es mostren els valors del DIC i del CPO per als dos models estimats. Observem que el model d'efectes fixos té menor DIC i CPO que el model d'efectes aleatoris. Seguint amb el raonament anterior, seleccionem el model 1, d'efectes fixos.

*Taula 22. Criteris de selecció entre els models plantejats per avaluar la millora de la infecció òrgano-cavitària i l'impacte de les mesures preventives en cirurgia de còlon*


<b>Model</b>	<b>DIC</b>	<b>CPO</b>
<b>Model 1. Model amb efectes fixos</b>	350.2249	0.2748926
<b>Model 2. Model amb efectes fixos i aleatoris</b>	350.2254	0.2748927

### **MILLORA DE LA INFECCIÓ EN L'ESPAI QUIRÚRGIC INCISIONAL I L'IMPACTE DE LES MESURES EN CIRURGIA DE RECTE**

Per escollir entre els dos models estimats, el model logístic bayesià sense efectes aleatoris i el model logístic jeràrquic bayesià, ens fixem en la utilitat, o no, d'afegir al model logístic bayesià l'efecte dels hospitals. Aquesta decisió la prenem fixant-nos amb la precisió associada a l'efecte hospital del model jeràrquic que, com ja hem comentat, és la indicadora de si existeix variabilitat en les probabilitats d'infecció dels hospitals participant. La precisió ha estat de 18581.35, això vol dir que no hi ha hospitals que augmentin la probabilitat d'infecció, un cop aquesta ajustada per les mesures preventives i per les variables de tipologia de pacient i d'intervenció quirúrgica.

El gràfic següent, on es mostren els efectes dels hospitals, és la manera gràfica de mostrar aquesta manca de variabilitat entre hospitals. Observem que els seus efectes estan centrats al 0 i que no n'hi ha cap de significatiu.

Gràfic 13. Efectes aleatoris dels hospitals associats a la infecció incisional en cirurgia de recte estimats a partir del model 2.



A la següent taula es mostren els valors del DIC i del CPO per als dos models estimats. Observem que el model d'efectes fixos té menor DIC i CPO que el model d'efectes aleatoris. Seguint amb el raonament anterior, seleccionem el model 1, d'efectes fixos.

Taula 23. Criteris de selecció entre els models plantejats per avaluar la millora de la infecció incisional i l'impacte de les mesures preventives en cirurgia de recte

Model	DIC	CPO
Model 1. Model amb efectes fixos	279.3789	0.39269
Model 2. Model amb efectes fixos i aleatoris	279.3837	0.3926959

MILLORA DE LA INFECCIÓ EN L'ESPAI QUIRÚRGIC ÒRGANO-CAVITÀRIA I L'IMPACTE DE LES MESURES EN CIRURGIA DE RECTE


Per escollir entre els dos models estimats, el model logístic bayesià sense efectes aleatoris i el model logístic jeràrquic bayesià, ens fixem en la utilitat, o no, d'afegir al model logístic bayesià l'efecte dels hospitals. Aquesta decisió la prenem fixant-nos amb la precisió associada a l'efecte hospital del model jeràrquic que, com ja hem comentat, és la indicadora de si existeix



variabilitat en les probabilitats d'infecció dels hospitals participant. La precisió ha estat de 18563.15, això vol dir que no hi ha diferències entre els hospitals participants pel que fa a la probabilitat d'infecció.

El gràfic següent, on es mostren els efectes dels hospitals, és la manera gràfica de mostrar aquesta manca de variabilitat entre hospitals. Observem que els seus efectes estan centrats al 0 i que no n'hi ha cap de significatiu.

Gràfic 14. *Efectes aleatoris dels hospitals associats a la infecció òrgano-cavitària en cirurgia de recte estimats a partir del model 2.*



A la següent taula es mostren els valors del DIC i del CPO per als dos models estimats. Observem que el model d'efectes fixos té major DIC i CPO que el model d'efectes aleatoris, però seguint amb el raonament anterior, seleccionem el model 1, d'efectes fixos.

Taula 24. *Criteris de selecció entre els models plantejats per avaluar la millora de la infecció òrgano-cavitària i l'impacte de les mesures preventives en cirurgia de recte*

Model	DIC	CPO
<b>Model 1. Model amb efectes fixos</b>	248.2737	0.3477427
<b>Model 2. Model amb efectes fixos i aleatoris</b>	248.2713	0.3477392

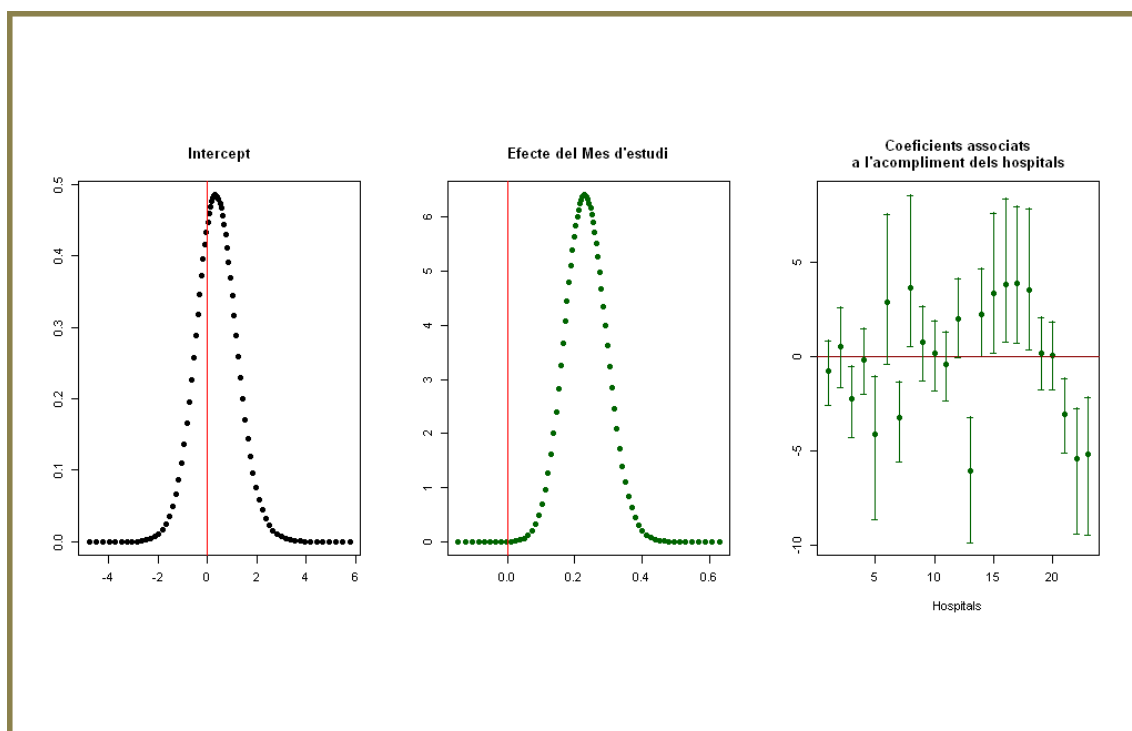
### 3.1.5 Interpretació dels models

Un cop seleccionats els millors models ajustats, en aquest apartat interpretarem els resultats i obtindrem les respostes a les preguntes plantejades inicialment.

#### **MILLORA DE L'ACOMPLIMENT DE LES MESURES PREVENTIVES**

En l'apartat anterior hem vist que el millor model ajustat és aquell que té en compte l'efecte hospital com a efecte aleatori i el temps com efecte fix. A continuació es mostren els tres gràfics corresponents a les distribucions a posteriori dels coeficients estimats.

*Gràfic 15. Distribucions a posteriori dels paràmetres del model seleccionat per a l'avaluació de la millora de l'acompliment de les mesures preventives*



La primera campana que s'observa és la distribució a posteriori del coeficient associat a l'*intercept*. Observem que la campana es troba centrada al 0, fet que indica que, a l'inici del projecte, la probabilitat mitjana que a un pacient se li apliquessin el conjunt de mesures

preventives de la IEQ era del 50% ( $\exp(0) = 1 = Odds Ratio = \frac{P(\text{Aplicar les mesures})}{P(\text{No aplicar les mesures})}$ ).

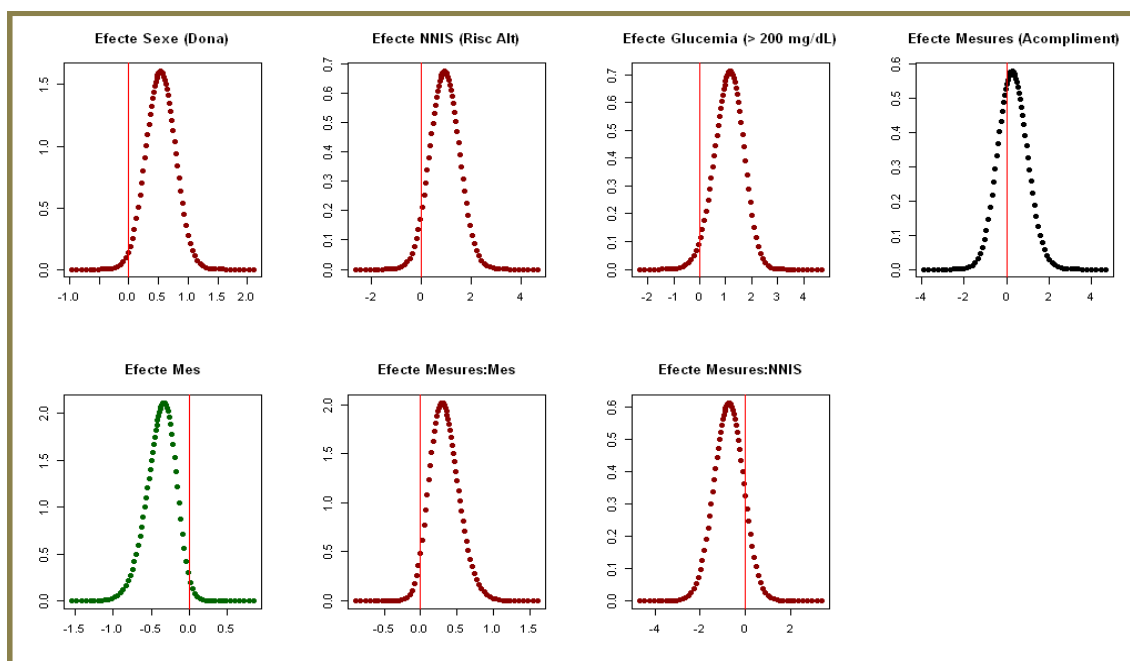
Aquesta probabilitat varia segons l'hospital participant al qual ha estat intervingut el pacient, tal i com mostra el tercer gràfic que correspon a la mitjana i interval de credibilitat del 95% de la distribució a posteriori dels coeficients associats a l'acompliment del conjunt de mesures preventives de cada un dels hospitals.

En el gràfic del mig hi ha representada la distribució a posteriori del coeficient associat a l'efecte del mes d'estudi en que s'havia realitzat la intervenció. Observem que la campana es troba desplaçada cap a la dreta del 0 i, per tant, sembla que les intervencions realitzades en els mesos més avançats de l'estudi tenien una probabilitat més alta d'aplicació del conjunt de mesures preventives.

### MILLORA DE LA INFECCIÓ EN L'ESPAI QUIRÚRGIC INCISIONAL I L'IMPACTE DE LES MESURES EN CIRURGIA DE CÒLON

Per a la interpretació del model seleccionat plantejem 4 escenaris que intenten respondre a les preguntes formulades per als objectius col·laboratius.

*Gràfic 16. Distribucions a posteriori dels paràmetres del model seleccionat per a l'avaluació de la millora de la infecció incisional i l'impacte de les mesures preventives en cirurgia de còlon*

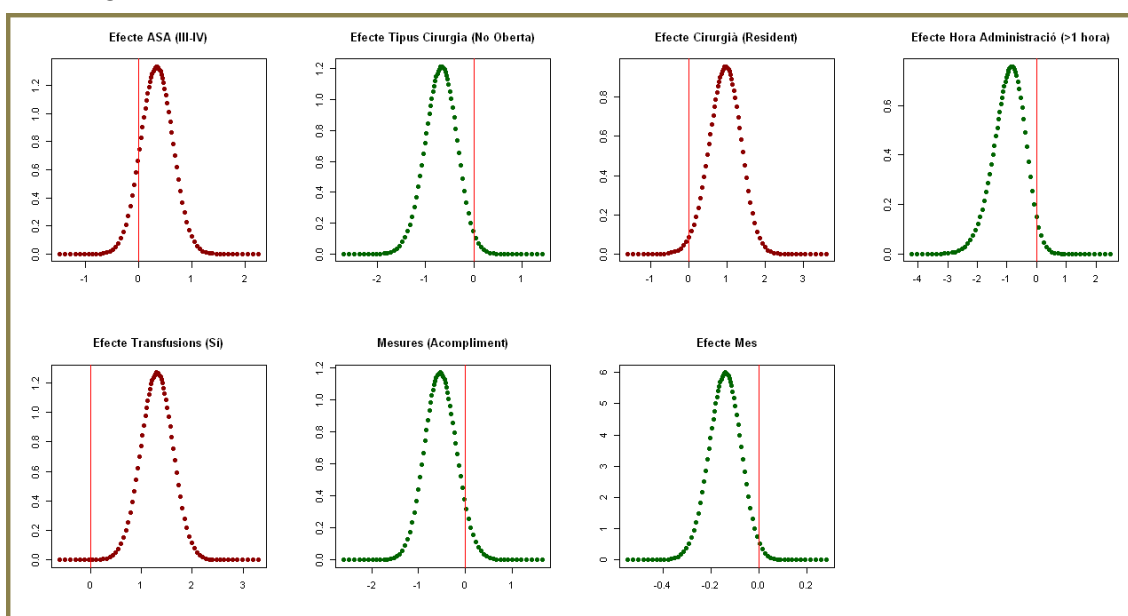


- a) *Un pacient sense aplicació de les mesures preventives:* Si comparem la probabilitat d'infecció que té un pacient a qui no se li han aplicat el conjunt de mesures preventives intervingut al primer mes de l'estudi amb un amb les mateixes característiques a qui tampoc se li han aplicat les mesures operat al novè mes de l'estudi, aquest últim té menys probabilitat d'infectar-se que el primer. **La probabilitat d'infecció disminueix a través dels mesos en què s'ha realitzat l'estudi en els pacients a qui no se'ls apliquen les mesures.**
- b) *Un pacient amb l'aplicació de les mesures preventives:* Un pacient a qui no se li han aplicat les mesures preventives intervingut durant el primer mes d'estudi té la mateixa probabilitat d'infectar-se que un pacient amb les mateixes característiques a qui també se li han aplicat les mesures preventives operat al novè mes. **La probabilitat d'infecció es manté igual en tots els mesos d'estudi en els pacients amb les mesures preventives aplicades.**
- c) *Un pacient amb alt risc d'infecció NNIS amb les mesures preventives aplicades:* Un pacient amb alt risc d'infecció a qui li han aplicat el conjunt de mesures preventives té menys probabilitat d'infectar-se que un pacient de les mateixes característiques a qui no se li han aplicat les mesures preventives. **Aplicar les mesures preventives en els pacients amb un risc d'infecció alt disminueix la probabilitat d'infecció.**
- d) *Un pacient amb baix risc d'infecció NNIS amb les mesures preventives aplicades:* Un pacient amb baix risc d'infecció a qui no li han aplicat el conjunt de mesures preventives té la mateixa probabilitat d'infectar-se que un pacient de les mateixes característiques a qui li han aplicat les mesures preventives. **Aplicar les mesures preventives en els pacients amb un baix risc d'infecció no disminueix la probabilitat d'infecció.**

### MILLORA DE LA INFECCIÓ EN L'ESPAI QUIRÚRGIC ÒRGANO-CAVITÀRIA I L'IMPACTE DE LES MESURES EN CIRURGIA DE CÒLON

Per a la interpretació del model seleccionat plantejem 2 escenaris que intenten respondre a les preguntes formulades per als objectius del col·laboratiu.

Gràfic 17. *Distribucions a posteriori dels paràmetres del model seleccionat per a l'avaluació de la millora de la infecció òrgano-cavitària i l'impacte de les mesures preventives en cirurgia de còlon*

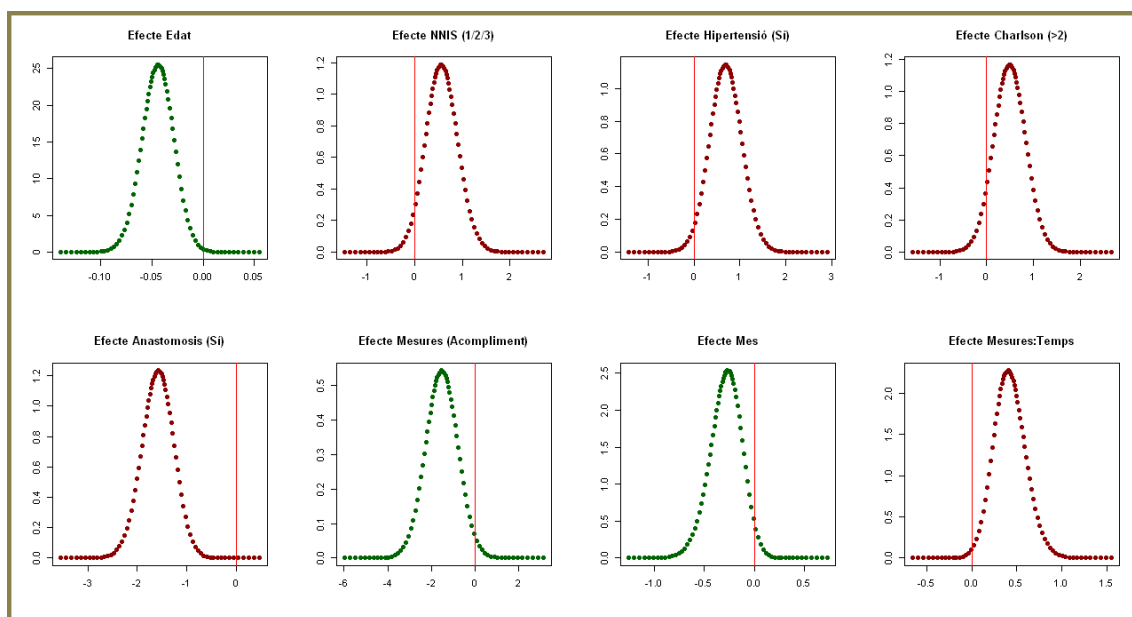


- a) *Un pacient amb l'aplicació de les mesures preventives:* Un pacient a qui se li han aplicat el conjunt de mesures preventives té menys probabilitat d'infectar-se que un pacient a qui no se li han aplicat. **Una menor probabilitat d'infecció es pot associar amb un major acompliment de les mesures preventives.**
- b) *L'efecte del temps:* Un pacient intervingut durant el primer mes té més probabilitat d'infectar-se que un pacient amb les mateixes característiques operat a l'últim mes. **La probabilitat d'infecció es redueix durant els mesos d'estudi.**

### MILLORA DE LA INFECCIÓ EN L'ESPAI QUIRÚRGIC INCISIONAL I L'IMPACTE DE LES MESURES EN CIRURGIA DE RECTE

Per a la interpretació del model seleccionat plantejem 3 escenaris que intenten respondre a les preguntes formulades per als objectius.

*Gràfic 18. Distribucions a posteriori dels paràmetres del model seleccionat per a l'avaluació de la millora de la infecció incisional i l'impacte de les mesures preventives en cirurgia de recte*



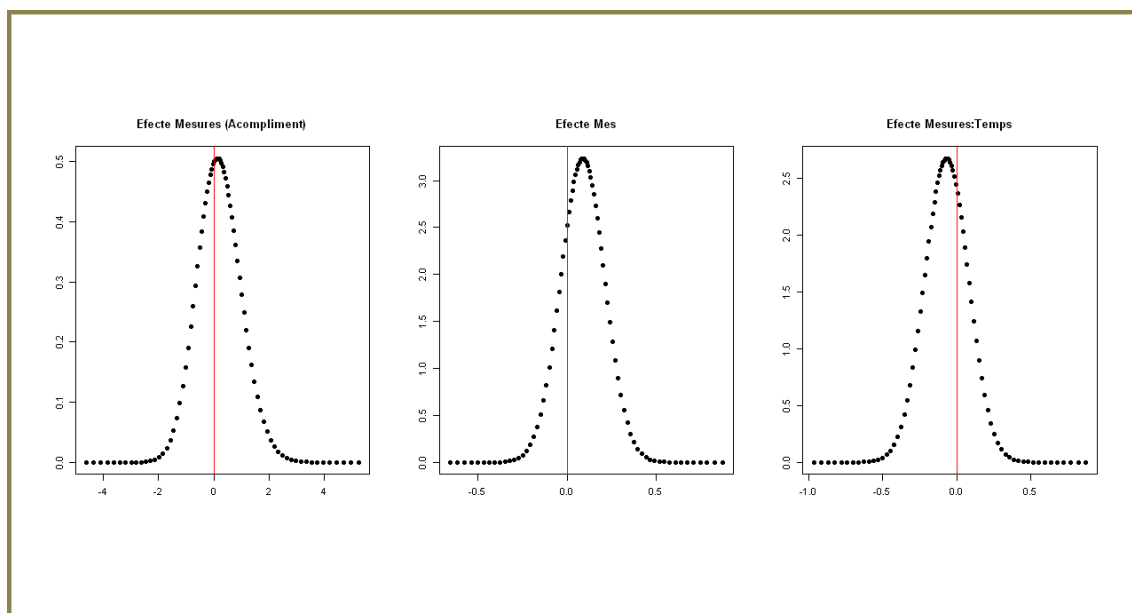
- a) *Un pacient amb l'aplicació de les mesures preventives:* Un pacient a qui se li han aplicat el conjunt de mesures preventives té menys probabilitat d'infectar-se que un pacient a qui no se li han aplicat. **La probabilitat d'infecció és menor en els pacients a qui se'ls han aplicat el conjunt de mesures preventives.**
- b) *Un pacient amb l'aplicació de les mesures preventives:* Un pacient a qui se li han aplicat el conjunt de mesures preventives durant el primer mes no té més probabilitat d'infectar-se que un pacient amb les mateixes característiques operat a l'últim mes. **La probabilitat d'infecció no disminueix en els pacients amb compliment de les mesures preventives.**
- c) *Un pacient sense l'aplicació de les mesures preventives:* Un pacient a qui no se li han aplicat el conjunt de mesures preventives durant el primer mes té més probabilitat

d'infectar-se que un pacient amb les mateixes característiques operat a l'últim mes. **La probabilitat d'infecció es redueix en els pacients sense acompliment de les mesures preventives.**

### **MILLORA DE LA INFECCIÓ EN L'ESPAI QUIRÚRGIC ÒRGANO-CAVITÀRIA I L'IMPACTE DE LES MESURES EN CIRURGIA DE RECTE**

Per aquest model no s'ha estimat cap efecte relacionat amb les variables del pacient i de la intervenció quirúrgica. Tampoc s'ha trobat cap relació entre l'acompliment de les mesures preventives i la probabilitat d'infecció ni cap efecte de millora o empitjorament d'aquesta.

*Gràfic 19. Distribucions a posteriori dels paràmetres del model seleccionat per a l'avaluació de la millora de la infecció òrgano-cavitària i l'impacte de les mesures preventives en cirurgia de recte*



## 3.2 PROJECTE PREVENCIÓ DE CAIGUDES: Projecte col·laboratiu de pràctiques segures en la prevenció de caigudes de pacients.

### 3.2.1 Contextualització

En el marc de l'Aliança per la Seguretat dels Pacients i el Col·legi d'Infermeria de Barcelona, és va dur a terme el projecte de "prevenció de caigudes i llessions associades en pacients ingressats", un projecte col·laboratiu entre Hospitals d'Aguts i Centres Sociosanitaris que va ser realitzat en un període de 6 mesos (nov'07 fins abril'08). Les unitats participants per cada Centres podien ser la unitat mèdica, la unitat quirúrgica i la unitat de salut mental. Els Centres podien copartipar amb una, dos o les tres unitats mencionades.

La recollida de dades va consistir en la complementació d'un seguit de formularis amb la intensió de registrar totes les caigudes que s'havien produït durant el període d'estudi, l'àmbit en què s'havien produït, el nombre total d'estades hospitalàries, el percentatge de mesures preventives que s'havien complert i si el centre disposava d'un Programa de Prevenció de Caigudes i el seu contingut.

*Taula 25. Llistat del conjunt de mesures preventives de les caigudes de pacient*

<b>Mesures del Pacient</b>	◆ Sabates antilliscants tancades i ben posades
	◆ El pacient té el llit en posició baixa
	◆ Hi ha un registre específicant com es faran les transferències (amb ajut, grues, etc.)
<b>Mesures del Professional</b>	◆ El timbre està a l'abast del pacient
	◆ El pacient està registrat com a pacient de risc de caigudes a la Història Clínica
	◆ El pacient o la família ha rebut informació de prevenció de caigudes
<b>Mesures de la Organització</b>	◆ El pacient està ubicat a una habitació propera a l'estació d'infermeria
	◆ Té el lavabo correctament senyalitzat
	◆ Té terra antilliscant a la dutxa

Les respostes que s'intentaran trobar amb l'anàlisi de les dades recollides per aquest projecte són:



1 – Ha millorat l'acompliment de les mesures preventives?

2 – Ha millorat la Taxa de caigudes?

3 – Ha tingut algun impacte sobre la taxa de caigudes haver complert les mesures preventives?

4 – Ha tingut algun impacte sobre la taxa de caigudes la presència d'un programa de prevenció de caigudes?

### 3.2.2 Anàlisi descriptiva de les dades

48 centres de Catalunya, 12 (25%) sociosanitaris i 36 (75%) hospitalaris, van participar al projecte CAIGUDES, observant un total de 482040 estàncies (89455 en els centres sociosanitaris i 392585 en els hospitals) i 1088 caigudes (252 en els centres sociosanitaris i 836 en els hospitals). La taxa de caigudes observada durant aquest període ha estat de 2.26 caigudes per 1000 dies d'estàncies (2.82 en els centres sociosanitaris i 2.13 en els hospitals).

*Taula 26. Descripció de la taxa de caigudes per tipologia de centre i les diferents unitats participants*


		Estàncies	Caigudes	Taxa de Caigudes
<b>Centres</b>	◆ <b>Unitat 1</b>	66265	180	2.72
<b>Sociosanitaris</b>	◆ <b>Unitat 2</b>	23190	72	3.10
	◆ <b>Unitat de Salut Mental</b>	42349	116	2.74
<b>Hospitals</b>	◆ <b>Unitat Mèdica</b>	195968	523	2.67
	◆ <b>Unitat Quirúrgica</b>	154268	197	1.28

A la taula anterior s'observen les taxes de caigudes per a cada una de les unitats avaluades dels centres participants, s'observa que la unitat amb menor taxa de caigudes és la Unitat Quirúrgica dels hospitals, mentre que la que ha tingut una major taxa de caigudes és la Unitat 2 dels centres sociosanitaris.


El període estudiat, comprès entre novembre de 2007 i abril de 2008, es va estratificar quinzenalment, sumant un total de 12 quinzenes. D'aquesta manera, es va obtenir la taxa de caigudes, per cada un dels centres i unitats, amb una periodicitat bimensual. En cada un dels talls de recol·lecta, també s'hi registrava el percentatge de mesures preventives que s'havien dut a terme durant aquell període de temps.

En el primer gràfic es representa l'evolució global de la taxa de les caigudes i del percentatge de mesures preventives complertes durant el període estudiat. S'observa que la taxa de caigudes sembla presenciar una tendència a la reducció d'aquesta (taxa de caigudes a la quinzena 1, 2.72; taxa de caigudes a la quinzena 12, 1.46) i el percentatge de compliment de les mesures preventives segueix una tendència a l'augment (percentatge de compliment a la quinzena 1, 65.75%; percentatge de compliment a la quinzena 12, 75.59%).

*Gràfic 20. Evolució de la taxa de caigudes i l'acompliment de les mesures preventives*




Gràfic 21. Evolució de la taxa de caigudes i l'acompliment de les mesures preventives de les diferents unitats participants dels centres sociosanitaris



Si ens fixem en els centres sociosanitaris, s'observa que, globalment, tant la taxa de caigudes com el compliment de les mesures preventives segueixen el mateix comportament que el comentat anteriorment, les caigudes disminueixen i les mesures augmenten. Ara bé, a nivell individual de les unitats d'aquests centres, de la Unitat 2 es pot destacar el pic en la taxa de caigudes observat en la quinzena 7 i que no segueix una tendència a la reducció d'aquesta taxa.

Gràfic 22. Evolució de la taxa de caigudes i l'acompliment de les mesures preventives de les diferents unitats participants dels hospitals



De l'evolució de la taxa de caigudes i del percentatge de mesures preventives aplicades en els hospitals, s'ha de destacar que la primera sembla que disminueixi a un ritme més lent que per als centres sociosanitaris, a nivell global dels hospitals. Si tenim en compte la diferència entre les unitats, s'observa que la Unitat Mèdica té una taxa de caigudes per sobre de la mitja global, mentre que la de la Unitat Quirúrgica es situa per sota. Pel que fa al compliment de les mesures preventives, el percentatge que s'observa en les Unitats Quirúrgiques és més elevat que la mitja global.

La taula següent descriu les variables relacionades amb la disponibilitat del centre d'un Programa de Prevenció de caigudes i la seva implementació. No s'observen gaires diferències entre tipologia de centre pel que fa a la presència del Programa ni la seva implementació, tot i que sembla que els centres sociosanitaris realitzen menys difusió dels resultats del Programa que els centres hospitalaris.

Taula 27. Descripció de les variables relacionades amb el Programa de prevenció de caigudes i el seu contingut

CARACTERÍSTIQUES DEL PROGRAMA DE PREVENCIÓ								
		Global		CSS		Hospital		
		N	%	N	%	N	%	
<i>Els centre disposa d'un Programa de prevenció de caigudes</i>	No	14	29.17	3	25.00	11	30.56	
	Sí	34	70.83	9	75.00	25	69.44	
<i>El Programa es troba implementat a tot el centre</i>	No	5	14.71	1	11.11	4	16.00	
	Sí	29	85.29	8	88.89	21	84.00	
<i>El Programa compren la identificació del risc de caiguda</i>	No	9	27.27	3	33.33	6	25.00	
	Si	24	72.73	6	66.67	18	75.00	
<i>El Programa compren la difusió periòdica de l'anàlisi i els resultats del Programa als equips assistencials</i>	No	13	40.62	5	55.56	8	34.78	
	Si	19	59.38	4	44.44	15	65.22	

### 3.2.3 Estimació dels models

En aquest apartat s'estimaran els models estadístics que ajudaran a respondre les preguntes plantejades pel projecte col·laboratiu.

## MILLORA DE L'ACOMPLIMENT DE LES MESURES PREVENTIVES

### Model Lineal amb Resposta Normal Bayesià

$$Y_i \sim \text{Normal}(\mu_i, \sigma)$$

$$E[Y_i | \beta_0, \beta_1, \beta_2] = \mu_i$$

$$\eta = g(\mu_i) = \mu_i = \beta_0 + \beta_1 \text{Quinzena}_i + \beta_2 \text{Tipus de Centre}_i$$

$$\Pi(\beta_0) = \Pi(\beta_1) = \Pi(\beta_2) = \text{Normal}(0, 0.001)$$

$$\tau \sim \text{logGamma}(0.01, 0.001), \text{ on } \tau = \frac{1}{\sigma}$$

Tal i com està dissenyada la base de dades que recull el percentatge de mesures preventives complertes (el mateix passa amb el nombre de caigudes i estàncies) durant el període quinzenal avaluat, els registres venen definits per la parella Unitat-Centre. En aquest model es considera que cada una d'aquestes parelles és independent de les altres, sense tenir en compte ni el centre ni la unitat a la que pertanyen. Suposem, doncs, que la variable aleatòria  $Y_i$  és el percentatge de mesures preventives dutes a terme per la parella Unitat-Centre  $i$ , durant la quinzena definida per la variable aleatòria  $Quinzena_i$ . Es considera que aquesta variable  $Y_i$  segueix una distribució Normal (p-valor del test de Normalita Shapiro – Wilks: 0.2961) centrada en  $\mu_i$  i desviació estàndard  $\sigma$ . Aquest model també ajustarà el percentatge de mesures preventives aplicades segons la tipologia del centre del qual pertany la parella avaluada.

*Taula 28. Estimació puntual i interval de confiança dels paràmetres del Model Lineal amb Resposta Normal Bayesià per a l'acompliment de les mesures preventives*

	<b>Coefficient</b>	
	Puntual	IC 95%
<b>Intercept</b>	0.70	0.67 - 0.74
<b>Quinzena</b>	0.009	0.006 - 0.012
<b>Tipus de centre. Hospital</b>	-0.06	-0.08 - -0.03

#### Model Lineal Jeràrquic amb Resposta Normal. El centre com a efecte aleatori

$$Y_{ij} \sim \text{Normal}(\mu_{ij}, \sigma)$$

$$i = 1, \dots, 48 \text{ centres}$$

$$j = 1, \dots, 5 \text{ unitats}$$

$$E[Y_{ij} | \beta_0, \beta_1, \beta_2, b_i] = \mu_{ij}$$

$$\eta = g(\mu_{ij}) = \mu_{ij} = \beta_0 + \beta_1 \text{Quinzena}_{ij} + \beta_2 \text{Tipus de Centre}_{ij} + b_i$$

$$\Pi(\beta_0) = \Pi(\beta_1) = \Pi(\beta_2) = \text{Normal}(0, 0.001)$$

$$\Pi(b_i) = \text{Normal}(0, \tau_h)$$

$$\tau, \tau_h \sim \text{logGamma}(0.01, 0.001), \text{ on } \tau = \frac{1}{\sigma^2}.$$

Prenem de partida el model especificat anteriorment. Observem com a diferència nous paràmetres a estimar,  $b_i$ . Aquests paràmetres correspon a la estructura jeràrquica que

proposa aquest model que considera que les parelles comentades Centre-Unitat ja no són independents les unes amb les altres, sinó que tenen un factor comú que és el Centre al qual pertanyen.

Els coeficients  $b_i$  segueixen una distribució *Normal* centrada al 0, però amb una precisió desconeguda que el model estimarà,  $\tau_h$ . Si aquesta precisió resulta ser molt petita, voldrà dir que hi ha diferències en el percentatge de mesures preventives utilitzades entre els centres participants; al contrari, la precisió serà molt gran.

La taula següent recull els coeficients fixos estimats juntament amb l'interval de credibilitat del 95%. També s'hi especifica el valor de la precisió dels hospitals estimada.

*Taula 29. Estimació puntual i interval de confiança dels paràmetres del Model Lineal Jeràrquic amb resposta Normal Bayesià, amb efecte aleatori centre, per a l'acompliment de les mesures preventives*

	<b>Coefficient</b>	
	Puntual	IC 95%
<b>Intercept</b>	0.69	0.63 - 0.74
<b>Quinzena</b>	0.008	0.006 - 0.01
<b>Tipus de centre. Hospital</b>	-0.04	-0.09 - 0.01
<b>Precisió (<math>\tau_h</math>)</b>	158.08	86.23 - 259.28

Si volem saber si els hospitals han millorat de manera diferent el percentatge de mesures preventives aplicades, només cal modificar el model anterior amb nous paràmetres aleatoris de la següent manera.

$$\begin{aligned}
 &Y_{ij} \sim \text{Normal}(\mu_{ij}, \sigma) \\
 &i = 1, \dots, 48 \text{ centres} \\
 &j = 1, \dots, 5 \text{ unitats} \\
 &E[Y_{ij} | \beta_0, \beta_1, b_{0i}, b_{1i}] = \mu_{ij} \\
 &\eta = g(\mu_{ij}) = \mu_{ij} = \beta_0 + \beta_1 \text{Tipus de Centre}_{ij} + b_{0i} + b_{1i} \text{Quinzena}_{ij} \\
 &\Pi(\beta_0) = \Pi(\beta_1) = \text{Normal}(0, 0.001) \\
 &\Pi(b_{0i}) = \Pi(b_{1i}) = \text{Normal}(0, \tau_{kh}) \\
 &\tau, \tau_{kh} \sim \text{logGamma}(0.01, 0.001), \text{ on } \tau = \frac{1}{\sigma^2} \text{ i } k = 0, 1.
 \end{aligned}$$

Taula 30. Estimació puntual i interval de confiança dels paràmetres del Model Lineal Jeràrquic amb resposta Normal Bayesià, amb el temps com a efecte aleatori associat al centre per a l'acompliment de les mesures preventives

	Coeficient	
	Puntual	IC 95%
<b>Intercept</b>	0.72	0.67 - 0.77
<b>Tipus de centre. Hospital</b>	-0.05	-0.10 - 0.003
<b>Precisió (<math>\tau_{0h}</math>)</b>	201.442	90.619 – 384.405
<b>Precisió (<math>\tau_{1h}</math>)</b>	14821.817	6047.198 – 31247.094

#### Model Lineal Jeràrquic amb Resposta Normal. La Unitat com a efecte aleatori

$$Y_{ij} \sim \text{Normal}(\mu_{ij}, \sigma)$$

$$i = 1, \dots, 5 \text{ unitats}$$

$$j = 1, \dots, 48 \text{ centres}$$

$$E[Y_{ij} | \beta_0, \beta_1, \beta_2, b_i] = \mu_{ij}$$

$$\eta = g(\mu_{ij}) = \mu_{ij} = \beta_0 + \beta_1 \text{Quinzena}_{ij} + \beta_2 \text{Tipus de Centre}_{ij} + b_i$$

$$\Pi(\beta_0) = \Pi(\beta_1) = \Pi(\beta_2) = \text{Normal}(0, 0.001)$$

$$\Pi(b_i) = \text{Normal}(0, \tau_u)$$

$$\tau, \tau_u \sim \text{logGamma}(0.01, 0.001), \text{ on } \tau = \frac{1}{\sigma^2}$$

Aquest nou model té la mateixa especificació que quan ajustàvem per l'efecte aleatori centre, però en aquest cas, l'estructura jeràrquica considera el factor comú de les parelles Centre-Unitat és la Unitat al quan pertanyen.

Els coeficients  $b_i$  segueixen una distribució *Normal* centrada al 0, però amb una precisió desconeguda que el model estimarà,  $\tau_u$ . Si aquesta precisió resulta ser molt petita, voldrà dir que hi ha diferències en el percentatge de mesures preventives utilitzades entre les unitats participants; al contrari, la precisió serà molt gran.



Taula 31. Estimació puntual i interval de confiança dels paràmetres del Model Lineal Jeràrquic amb resposta Normal Bayesià, amb efecte aleatori unitat, per a l'acompliment de les mesures preventives

	Coeficient	
	Puntual	IC 95%
<b>Intercept</b>	0.71	0.65 - 0.77
<b>Quinzena</b>	0.008	0.006 - 0.01
<b>Tipus de centre. Hospital</b>	-0.07	-0.14 - 0.003
<b>Precisió (<math>\tau_u</math>)</b>	1168.597	204.495 - 3534.582

Si volem saber si les unitats han evolucionat de manera diferent pel que fa al percentatge de mesures preventives aplicades, només cal modificar el model anterior amb nous paràmetres aleatoris de la següent manera.

$$Y_{ij} \sim \text{Normal}(\mu_{ij}, \sigma)$$

$$i = 1, \dots, 5 \text{ unitats}$$

$$j = 1, \dots, 48 \text{ centres}$$

$$E[Y_{ij} | \beta_0, \beta_1, b_{0i}, b_{1i}] = \mu_{ij}$$

$$\eta = g(\mu_{ij}) = \mu_{ij} = \beta_0 + \beta_1 \text{Tipus de Centre}_{ij} + b_{0i} + b_{1i} \text{Quinzena}_{ij}$$

$$\Pi(\beta_0) = \Pi(\beta_1) = \text{Normal}(0, 0.001)$$

$$\Pi(b_{0i}) = \Pi(b_{1i}) = \text{Normal}(0, \tau_{ku})$$

$$\tau, \tau_{ku} \sim \log\text{Gamma}(0.01, 0.001), \text{ on } \tau = \frac{1}{\sigma^2} \text{ i } k = 0, 1.$$

Taula 32. Estimació puntual i interval de confiança dels paràmetres del Model Lineal Jeràrquic amb resposta Normal Bayesià, amb el temps com a efecte aleatori associat a la unitat per a l'acompliment de les mesures preventives

	Coeficient	
	Puntual	IC 95%
<b>Intercept</b>	0.74	0.68 - 0.80
<b>Tipus de centre. Hospital</b>	-0.09	-0.16 - -0.03
<b>Precisió (<math>\tau_{0u}</math>)</b>	13341.82	344.44 - 83175.01
<b>Precisió (<math>\tau_{1u}</math>)</b>	20713.74	4861.37 - 53095.43

### Model Lineal Jeràrquic amb Resposta Normal. La Unitat anidada al Centre

$$\begin{aligned}
 Y_{ij} &\sim \text{Normal}(\mu_{ij}, \sigma) \\
 i &= 1, \dots, 48 \text{ centres} \\
 j &= 1, \dots, 5 \text{ unitats} \\
 E[Y_{ij} | \beta_0, \beta_1, \beta_2, b_i, b_{ij}] &= \mu_{ij} \\
 \eta = g(\mu_{ij}) = \mu_{ij} &= \beta_0 + \beta_1 \text{Quinzena}_{ij} + \beta_2 \text{Tipus de Centre}_{ij} + b_i + b_{ij} \\
 \Pi(\beta_0) = \Pi(\beta_1) = \Pi(\beta_2) &= \text{Normal}(0, 0.001) \\
 \Pi(b_i) &= \text{Normal}(0, \tau_h) \\
 \Pi(b_{ij}) &= \text{Normal}(0, \tau_{hu}) \\
 \tau, \tau_h, \tau_{hu} &\sim \log\text{Gamma}(0.01, 0.001), \text{ on } \tau = \frac{1}{\sigma^2}.
 \end{aligned}$$

Considerem aquest últim model on la variable aleatòria  $Y_{ij}$  representa el percentatge de mesures preventives complertes per la unitat  $j$  pertanyent al hospital  $i$  durant la quinzena especificada per la variable explicativa  $\text{Quinzena}_{ij}$ . Aquest model presenta una estructura jeràrquica de dos nivells, amb un primer nivell representat pel factor Centre i un segon nivell representat pel factor Unitat que depèn del factor Centre.

Els coeficients  $b_i$  i  $b_{ij}$  segueixen una distribució *Normal* centrada al 0, però amb una precisió desconeguda que el model estimarà,  $\tau_h$  i  $\tau_{hu}$ . Si aquestes precisions resulten ser molt petites, voldrà dir que hi ha diferències en el percentatge de mesures preventives utilitzades entre les els centres i les unitats dins dels centres participants; al contrari, la precisió serà molt gran.

Taula 33. Estimació puntual i interval de confiança dels paràmetres del Model Lineal Jeràrquic amb resposta Normal Bayesià, amb la unitat dependent del centre com a efectes aleatoris, per a l'acompliment de les mesures preventives

	Coeficient	
	Puntual	IC 95%
<b>Intercept</b>	0.70	0.63 - 0.76
<b>Quinzena</b>	0.008	0.006 - 0.01
<b>Tipus de centre. Hospital</b>	-0.04	-0.12 - 0.03
<b>Precisió (<math>\tau_h</math>)</b>	235.42	95.94 - 505.53
<b>Precisió (<math>\tau_{hu}</math>)</b>	150.81	91.43 - 234.57

## MILLORA DE LA TAXA DE CAIGUDES I LA SEVA RELACIÓ AMB L'ACOMPLIMENT DE LES MESURES PREVENTIVES I TENIR EL PROGRAMA DE PREVENCIÓ DE CAIGUDES

### Model amb Resposta Poisson

$$Y_i \sim \text{Poisson}(\lambda_i)$$

$$E[Y_i | \beta_0, \beta_K] = \lambda_i$$

$$\eta = g(\lambda_i) = \log(\lambda_i) = \beta_0 + \sum_{k=1}^p \beta_k X_{ki} + \text{outlier}_i + \log(\text{NombreEstàncies}_i)$$

$$\Pi(\beta_0) = \Pi(\beta_k) = \text{Normal}(0, 0.001)$$

Com ja s'ha comentat anteriorment, les dades es van recollir a nivell de parella Unitat-Centre, per tant, en aquest model suposem que cada una d'aquestes parelles és independent, és a dir, que la variable aleatòria  $Y_i$  és el nombre de caigudes observades per la parella Unitat-Centre  $i$ . Aquest model està ajustat per un conjunt de variables relacionades amb la pertinença d'un Programa de prevenció de caigudes, la quinzena en què han estat recollides les caigudes i el percentatge de mesures preventives que s'han aplicat. Tot aquest conjunt de variables explicatives queda expressat a partir de  $X_{ki}$ . El  $\text{NombreEstàncies}_i$  correspon al nombre d'estàncies hospitalàries que s'han enregistrat en el mateix període de temps per la mateixa parella Unitat-Centre avaluada, i aquesta última variable es considera com a offset, no intervé en l'estimació dels paràmetres del model, però és imprescindible incloure-la ja que la taxa de caigudes es calcula a partir de:  $\text{taxaCaigudes} = \frac{\text{Nomre de caigudes}}{\text{Estàncies}} \times 1000$ .

Per acabar, també s'ajusta el model per una variable indicadora que pren valor 1 quan el valor de la taxa de caigudes observada és un outlier, i 0 quan no ho és. Aquesta variable és la que s'observa a l'especificació del model com a  $\text{outlier}_i$ .

Sota la perspectiva epidemiològica, el percentatge d'acompliment de les mesures preventives és una variable depenent del temps, el que vol dir que s'observarà entre un interval de temps especificat, la quinzena d'estudi. Definir el mètode apropiat per a analitzar aquest tipus de variable explicativa en models estadístics ha estat debatut en molts camps diferents, ja que sense un bon tractament pot produir el que s'anomena **biaix temps-depenent**.

A continuació estimarem dos models tractant, i sense tractar, la variable percentatge d'acompliment de les mesures preventives com a variable depenent del temps.

**Sense tenir en compte la temps-dependència de la variable percentatge de mesures preventives complertes**

Seguint el criteri d'incloure al model aquelles variables explicatives que disminueixin el DIC i/o el CPO, o que s'observi una distribució a posteriori dels coeficients de regressió no gaire centrada al 0, hem seleccionat aquelles variables que podrien tenir alguna relació amb la taxa de caigudes. Aquestes variables, introduïdes consecutivament al model, han estat: el percentatge de mesures preventives, la quinzena, tenir un Programa de Prevenció de caigudes, i el tipus de centre del que es tracta.

*Taula 34. Variables explicatives significatives en el model Bayesià amb Resposta Poisson per a la millora de la taxa de caigudes sense tenir en compte la temps-dependència del percentatge de mesures preventives*

◆ <b>Model nul</b>	DIC	3167.546
	CPO	1.481907
◆ <b>Percentatge Compliment Mesures Preventives (primera variable introduïda)</b>	DIC	3158.808
	CPO	1.478194
◆ <b>Quinzena (segona variable introduïda)</b>	DIC	3151.519
	CPO	1.475131
◆ <b>Programa de prevenció de caigudes (tercera variable introduïda)</b>	DIC	3148.262
	CPO	1.473914
◆ <b>Tipus de centre (CSS o Hospital) (quarta variable introduïda)</b>	DIC	3138.387
	CPO	1.46968

Un cop ajustat aquest primer model, ajustarem un segon model (només per aquells centres que disposen de Programa de Prevenció de Caigudes) per trobar si variables relacionades amb el Programa expliquen la taxa de caigudes dels centres. Aquestes variables són si el Programa està implantat a tot el centre, l'any d'implantació del Programa, si el Programa comprèn l'avaluació del Risc de caiguda dels pacients i si el Programa comprèn la difusió dels anàlisis i resultats del Programa.

*Taula 35. Variables explicatives referents al Programa de Prevenció de caigudes significatives en el model Bayesià amb Resposta Poisson per a la millora de la taxa de caigudes sense tenir en compte la temps-dependència del percentatge de mesures preventives*

◆ <b>Model nul</b>	DIC	3141.615
	CPO	1.470888
◆ <b>Implantació del Programa a tot el Centre</b> <i>(primera variable introduïda)</i>	DIC	3141.968
	CPO	1.471169
◆ <b>Any d'implantació del Programa</b> <i>(segona variable introduïda)</i>	DIC	3129.947
	CPO	1.465861
◆ <b>Valoració del Risc de Caigudes</b> <i>(tercera variable introduïda)</i>	DIC	3128.417
	CPO	1.46586
◆ <b>Difusió dels anàlisis i Resultats del Programa</b> <i>(quarta variable introduïda)</i>	DIC	3121.639
	CPO	1.462986

#### **Tenint en compte la temps-dependència de la variable percentatge de mesures preventives complertes**

La diferència entre aquest model i l'anterior és que la variable  $PercentatgeMesures_i$  està tractada juntament amb el producte amb el temps,  $PercentatgeMesures_i:Quinzena_i$ . Aquest tractament és una de les propostes per tractar la temps-dependència d'aquesta variable i evitar el biaix produït en l'estimació de l'efecte del percentatge de mesures sobre la taxa de caigudes.

Amb el mateix criteri d'abans, hem observat que les variables que podrien estar relacionades amb la taxa de caigudes són:

Taula 36. Variables explicatives significatives en el model Bayesià amb Resposta Poisson per a la millora de la taxa de caigudes tenint en compte la temps-dependència del percentatge de mesures preventives

◆ <b>Model nul</b>	DIC	3167.546
	CPO	1.481907
◆ <b>Percentatge Cumpliment Mesures Preventives</b> <i>(primera variable introduïda)</i>	DIC	3148.39
	CPO	1.473187
◆ <b>Quinzena</b> <i>(segona variable introduïda)</i>	DIC	3148.109
	CPO	1.473533
◆ <b>Programa de prevenció de caigudes</b> <i>(tercera variable introduïda)</i>	DIC	3145.185
	CPO	1.472486
◆ <b>Tipus de centre (CSS o Hospital)</b> <i>(quarta variable introduïda)</i>	DIC	3134.775
	CPO	1.468004

Igual que pel cas anterior, ajustem per les variables relacionades amb el Programa de Prevenció.

Taula 37. Variables explicatives referents al Programa de Prevenció de caigudes significatives en el model Bayesià amb Resposta Poisson per a la millora de la taxa de caigudes tenint en compte la temps-dependència del percentatge de mesures preventives

◆ <b>Model nul</b>	DIC	3134.775
	CPO	1.468004
◆ <b>Implantació del Programa a tot el Centre</b> <i>(primera variable introduïda)</i>	DIC	3007.98
	CPO	1.407762
◆ <b>Any d'implantació del Programa</b> <i>(segona variable introduïda)</i>	DIC	3002.06
	CPO	1.40528
◆ <b>Difusió dels anàlisis i Resultats del Programa</b> <i>(tercera variable introduïda)</i>	DIC	2996.256
	CPO	1.402934

Si observem el DIC i el CPO dels models finals estimats, conclourem que és millor tractar la variable percentatge de mesures preventives complertes com a variable temps-dependent.

### Model Jeràrquic amb Resposta Poisson. El centre com a efecte aleatori

$$\begin{aligned}
 Y_{ij} &\sim \text{Poisson}(\lambda_{ij}) \\
 i &= 1, \dots, 48 \text{ centres} \\
 j &= 1, \dots, 5 \text{ unitats} \\
 [Y_{ij} | \beta_0, \beta_k, b_i] &= \lambda_{ij} \\
 \eta = g(\lambda_{ij}) = \log(\lambda_{ij}) &= \\
 &= \beta_0 + \sum_{k=1}^p \beta_k X_{kij} + \text{outlier}_{ij} + \log(\text{NombreEstàncies}_{ij}) + b_i \\
 \Pi(\beta_0) = \Pi(\beta_k) &= \text{Normal}(0, 0.001) \\
 \Pi(b_i) &= \text{Normal}(0, \tau_h) \\
 \tau_h &\sim \log\text{Gamma}(0.01, 0.001)
 \end{aligned}$$

Seguint amb l'especificació del model anterior, la variable aleatòria  $Y_{ij}$  correspon al nombre de caigudes observades en el centre  $i$  i la unitat  $j$ , però en aquest cas les parelles comentades, Centre-Unitat, tenen un factor comú que ve donat per al centre al qual pertanyen. D'aquesta manera, ja no es consideren parelles independents les unes amb les altres, sinó que es diu que el model presenta una estructura jeràrquica. Aquesta estructura jeràrquica ve donada per la introducció al model dels coeficients  $b_i$ .

Els coeficients  $b_i$  segueixen una distribució *Normal* centrada al 0, però amb una precisió desconeguda que el model estimarà,  $\tau_h$ . Si aquesta precisió resulta ser molt petita, voldrà dir que hi ha diferències en el nombre de caigudes entre el centres participants; al contrari, la precisió serà molt gran.

Primer introduïm els efectes aleatoris dels centres, i obtenim una estimació puntual de la precisió igual a 3.51. Seguint el criteri d'incloure al model aquelles variables explicatives que disminueixin el DIC i/o el CPO, o que s'observi una distribució a posteriori dels coeficients de regressió no gaire centrada al 0, hem seleccionat aquelles variables que podrien tenir alguna relació amb la taxa de caigudes. Aquestes variables, introduïdes consecutivament al model, es presenten a la taula següent.

Taula 38. Variables explicatives significatives en el model Jeràrquic amb Resposta Poisson, amb efecte aleatori centre, per a la millora de la taxa de caigudes tenint en compte la temps-dependència del percentatge de mesures preventives

◆ <b>Model nul</b>	DIC	2952.40
	CPO	---
◆ <b>Percentatge Cumpliment Mesures Preventives (primera variable introduïda)</b>	DIC	2938.949
	CPO	---
◆ <b>Quinzena (segona variable introduïda)</b>	DIC	2936.085
	CPO	---

La precisió dels coeficients dels hospitals per aquest model ajustat és de 4.536. Observem que a l'ajustar una estructura jeràrquica ha desaparegut l'efecte de l'existència d'un Programa de Prevenció de caigudes i la tipologia del centre.

Tot i que la variable Programa de Prevenció de caigudes no ha resultat significatiu en el model ajustat, provarem d'ajustar un nou model per aquells centres que sí disposen del programa per intentar trobar si variables relacionades amb el Programa expliquen la taxa de caigudes dels centres. Cap d'aquestes variables ha resultat significativa.

Continuant amb el model especificat amb efectes aleatoris associats als centres participants, el modifiquem una mica per avaluar si l'efecte del percentatge de mesures preventives aplicades i el temps varien segons el centre.

$$\begin{aligned}
 Y_{ij} &\sim \text{Poisson}(\lambda_{ij}) \\
 i &= 1, \dots, 48 \text{ centres} \\
 j &= 1, \dots, 5 \text{ unitats} \\
 [Y_{ij} | \beta_0, b_{0i}, b_{1i}, b_{2i}] &= \lambda_{ij} \\
 \eta = g(\lambda_{ij}) = \log(\lambda_{ij}) &= \\
 &= \beta_0 + \text{outlier}_{ij} + \log(\text{NombreEstàncies}_{ij}) + b_{0i} \\
 &+ b_{1i} \text{PercentatgeMesures}_{ij} + b_{2i} \text{Quinzena}_{ij}
 \end{aligned}$$

$$\Pi(\beta_0) = \text{Normal}(0, 0.001)$$

$$\Pi(b_{0i}) = \text{Normal}(0, \tau_{0h})$$



$$\begin{aligned}\Pi(b_{1i}) &= \text{Normal}(0, \tau_{1h}) \\ \Pi(b_{2i}) &= \text{Normal}(0, \tau_{2h}) \\ \tau_{0h}, \tau_{1h}, \tau_{2h} &\sim \text{logGamma}(0.01, 0.001)\end{aligned}$$

Observem que les precisions estimades són 4.415 per  $\tau_{0h}$ , 1714.148 per  $\tau_{1h}$  i 18992.366 per  $\tau_{2h}$ .

### **Model Jeràrquic amb Resposta Poisson. La unitat com a efecte aleatori**

$$\begin{aligned}Y_{ij} &\sim \text{Poisson}(\lambda_{ij}) \\ i &= 1, \dots, 5 \text{ unitats} \\ j &= 1, \dots, 48 \text{ centres} \\ [Y_{ij} | \beta_0, \beta_k, b_i] &= \lambda_{ij} \\ \eta = g(\lambda_{ij}) = \log(\lambda_{ij}) &= \\ &= \beta_0 + \sum_{k=1}^p \beta_k X_{kij} + \text{outlier}_{ij} + \log(\text{NombreEstàncies}_{ij}) + b_i \\ \Pi(\beta_0) = \Pi(\beta_k) &= \text{Normal}(0, 0.001) \\ \Pi(b_i) &= \text{Normal}(0, \tau_h) \\ \tau_u &\sim \text{logGamma}(0.01, 0.001)\end{aligned}$$

Aquest nou model té la mateixa especificació que quan ajustàvem per l'efecte aleatori centre, però en aquest cas, l'estructura jeràrquica considera el factor comú de les parelles Centre-Unitat és la Unitat al quan pertanyen.

Els coeficients  $b_i$  segueixen una distribució *Normal* centrada al 0, però amb una precisió desconeguda que el model estimarà,  $\tau_u$ . Si aquesta precisió resulta ser molt petita, voldrà dir que hi ha diferències en el nombre de caigudes entre les unitats avaluades; al contrari, la precisió serà molt gran.

Primer introduïm els efectes aleatoris de les unitats, i obtenim una estimació puntual de la precisió igual a 13.757. Seguint el criteri d'incloure al model aquelles variables explicatives que

disminueixin el DIC i/o el CPO, o que s'observi una distribució a posteriori dels coeficients de regressió no gaire centrada al 0, hem seleccionat aquelles variables que podrien tenir alguna relació amb la taxa de caigudes. Aquestes variables, introduïdes consecutivament al model, es presenten a la taula següent.

*Taula 39. Variables explicatives significatives en el model Jeràrquic amb Resposta Poisson, amb efecte aleatori unitat, per a la millora de la taxa de caigudes tenint en compte la temps-dependència del percentatge de mesures preventives*

◆ <b>Model nul</b>	DIC	3067.159
	CPO	---
◆ <b>Percentatge Cumpliment Mesures Preventives</b> <i>(primera variable introduïda)</i>	DIC	3052.172
	CPO	---
◆ <b>Quinzena</b> <i>(segona variable introduïda)</i>	DIC	3052.334
	CPO	---
◆ <b>Programa de prevenció de caigudes</b> <i>(tercera variable introduïda)</i>	DIC	3048.842
	CPO	---

La precisió dels coeficients de les unitats per aquest model ajustat és de 15.156.

Tot seguit ajustarem un nou model per aquells centres que sí disposen del Programa de Prevenció de caigudes per intentar trobar si variables relacionades amb aquest expliquen la taxa de caigudes.

*Taula 40. Variables explicatives referents al contingut del Programa de Prevenció de caigudes significatives en el model Jeràrquic amb Resposta Poisson, amb efecte aleatori unitat, per a la millora de la taxa de caigudes tenint en compte la temps-dependència del percentatge de mesures preventives*

◆ <b>Model nul</b>	DIC	3052.172
	CPO	---
◆ <b>Any d'implantació del Programa</b> <i>(primera variable introduïda)</i>	DIC	3041.425
	CPO	---
◆ <b>Valoració del Risc de Caigudes</b> <i>(segona variable introduïda)</i>	DIC	3041.88
	CPO	---
◆ <b>Difusió dels anàlisis i Resultats del Programa</b> <i>(tercera variable introduïda)</i>	DIC	3038.292
	CPO	---

Continuant amb el model especificat amb efectes aleatoris associats a les unitats avaluades, el modifiquem una mica per avaluar si l'efecte del percentatge de mesures preventives aplicades i el temps varien segons aquestes.

$$\begin{aligned}
 Y_{ij} &\sim \text{Poisson}(\lambda_{ij}) \\
 i &= 1, \dots, 5 \text{ unitats} \\
 j &= 1, \dots, 48 \text{ centres} \\
 [Y_{ij} | \beta_0, \beta_1, b_{0i}, b_{1i}, b_{2i}] &= \lambda_{ij} \\
 \eta = g(\lambda_{ij}) = \log(\lambda_{ij}) &= \\
 &= \beta_0 + \beta_1 \text{Programa}_{ij} + \text{outlier}_{ij} + \log(\text{NombreEstàncies}_{ij}) + b_{0i} \\
 &+ b_{1i} \text{PercentatgeMesures}_{ij} + b_{2i} \text{Quinzena}_{ij} \\
 \Pi(\beta_0) = \Pi(\beta_1) &= \text{Normal}(0, 0.001) \\
 \Pi(b_{0i}) &= \text{Normal}(0, \tau_{0u}) \\
 \Pi(b_{1i}) &= \text{Normal}(0, \tau_{1u}) \\
 \Pi(b_{2i}) &= \text{Normal}(0, \tau_{2u}) \\
 \tau_{0u}, \tau_{1u}, \tau_{2u} &\sim \log\text{Gamma}(0.01, 0.001)
 \end{aligned}$$

Observem que les precisions estimades són 29.490 per  $\tau_{0u}$ , 13815.775 per  $\tau_{1u}$  i 2357.220 per  $\tau_{2u}$ .

#### **Model Jeràrquic amb Resposta Poisson. La Unitat anidada al Centre**

$$\begin{aligned}
 Y_{ij} &\sim \text{Poisson}(\lambda_{ij}) \\
 i &= 1, \dots, 48 \text{ centres} \\
 j &= 1, \dots, 5 \text{ unitats} \\
 E[Y_{ij} | \beta_0, \beta_k, b_i, b_{ij}] &= \lambda_{ij} \\
 \eta = g(\lambda_{ij}) = \log(\lambda_{ij}) &= \\
 &= \beta_0 + \sum_{k=1}^p \beta_k X_{kij} + \text{outlier}_{ij} + \log(\text{NombreEstàncies}_{ij}) + b_i + b_{ij}
 \end{aligned}$$

$$\begin{aligned}\Pi(\beta_0) &= \Pi(\beta_k) = \text{Normal}(0, 0.001) \\ \Pi(b_i) &= \text{Normal}(0, \tau_h) \\ \Pi(b_{ij}) &= \text{Normal}(0, \tau_{hu}) \\ \tau_h, \tau_{hu} &\sim \text{logGamma}(0.01, 0.001)\end{aligned}$$

Considerem aquest últim model on la diferència respecte als models anteriors és que la variable aleatòria  $Y_{ij}$  representa el nombre de caigudes observades a la unitat  $j$  pertanyent al hospital  $i$ . Aquest model presenta una estructura jeràrquica de dos nivells, amb un primer nivell representat pel factor Centre i un segon nivell representat pel factor Unitat dependent del Centre al qual pertany.

Els coeficients  $b_i$  i  $b_{ij}$  segueixen una distribució *Normal* centrada al 0, però amb una precisió desconeguda que el model estimarà,  $\tau_h$  i  $\tau_{hu}$ . Si aquestes precisions resulten ser molt petites, voldrà dir que hi ha diferències en el nombre de caigudes observades entre les els centres i les unitats dins dels centres participants; al contrari, la precisió serà molt gran.

Les precisions estimades en aquest model quan encara no s'ha ajustat per cap variable explicativa són  $1.675e+04$  per  $\tau_h$  i  $1.956$  per  $\tau_{hu}$ . A continuació, seguint el mateix criteri que en els models anteriors, ajustem el model per les següents variables.

*Taula 41. Variables explicatives significatives en el model Jeràrquic amb Resposta Poisson, amb efecte aleatori unitat dependent de l'efecte aleatori centre, per a la millora de la taxa de caigudes tenint en compte la temps-dependència del percentatge de mesures preventives*

◆ <b>Model nul</b>	DIC	2763.09
	CPO	---
◆ <b>Percentatge Cumpliment Mesures Preventives (primera variable introduïda)</b>	DIC	2752.67
	CPO	---
◆ <b>Quinzena (segona variable introduïda)</b>	DIC	2748.797
	CPO	---
◆ <b>Programa de prevenció de caigudes (tercera variable introduïda)</b>	DIC	2747.737
	CPO	---
◆ <b>Tipus de centre (CSS o Hospital) (quarta variable introduïda)</b>	DIC	2747.092
	CPO	---

La precisió dels coeficients dels centres és de 1.707e+04, mentre que la de les unitats anidades dins dels centres és de 1.994.

Tot seguit ajustarem un nou model per aquells centres que sí disposen del Programa de Prevenció de caigudes per intentar trobar si variables relacionades amb aquest expliquen la taxa de caigudes.

*Taula 42. Variables explicatives referents al contingut del Programa de Prevenció significatives en el model Jeràrquic amb Resposta Poisson, amb efecte aleatori unitat dependent de l'efecte aleatori centre, per a la millora de la taxa de caigudes tenint en compte la temps-dependència del percentatge de mesures preventives*

◆ <b>Model nul</b>	DIC	2748.183
	CPO	---
◆ <b>Any d'implantació del Programa (primera variable introduïda)</b>	DIC	2746.159
	CPO	---
◆ <b>Valoració del Risc de Caigudes (segona variable introduïda)</b>	DIC	2745.609
	CPO	---
◆ <b>Difusió dels anàlisis i Resultats del Programa (tercera variable introduïda)</b>	DIC	2743.207
	CPO	---

### 3.2.4 Selecció dels models

Un cop estimats els possibles models candidats per a explicar cada un dels problemes plantejats, en aquesta secció seleccionarem el millor.

### MILLORA DE L'ACOMPLIMENT DE LES MESURES PREVENTIVES

Per fer la selecció del model més ben ajustat i passar a la interpretació d'aquest ens basarem, primerament en els valors obtinguts del DIC i el CPO. A la taula següent s'exposen aquests valors per cada un dels models estimats.


*Taula 43. Criteris de selecció entre els models plantejats per avaluar la millora de l'acompliment de les mesures preventives*

<b>Model</b>	<b>DIC</b>	<b>CPO</b>
<b>Model 1. Efectes Fixos de la millora de l'acompliment de les mesures</b>	-789.5452	-2.367578
<b>Model 2. Efectes Aleatoris de l'acompliment dels Centres</b>	-991.1617	-2.864649
<b>Model 2.B. Efectes Aleatoris de la millora dels Centres</b>	-985.863	-2.847656
<b>Model 3. Efectes Aleatoris de l'acompliment de les Unitats</b>	-836.6488	-2.502001
<b>Model 3.B. Efectes Aleatoris de la millora de les Unitats</b>	-832.528	-2.492714
<b>Model 4. Efectes Aleatoris de l'acompliment de les Unitats anidades dins dels Centres</b>	-1256.26	-3.770997

Tenint en compte el criteri que com menor sigui el número del DIC i del CPO, millor és el model, a partir de la taula anterior, seleccionariem el Model 4.


A continuació, es mostren els gràfics corresponents als efectes aleatoris associats a l'acompliment de les mesures preventives de cada model estimat.

Gràfic 23. Efectes Aleatoris de l'acompliment dels Centres estimats amb el model 2




En aquest gràfic s'observa que el valor del percentatge de mesures complertes al inici del projecte no era el mateix per tots els centres participants.

Gràfic 24. Efectes Aleatoris de la millora dels Centres estimats amb el model 2.B



Observem que sí que sembla que hi ha algun centre on la millora del percentatge de compliment de les mesures preventives ha estat millor que la resta de centres, però en general l'evolució ha estat homogènia.


Gràfic 25. *Efectes Aleatoris de l'acompliment de les Unitats estimats amb el Model 3*



Observem que només hi ha una unitat, la unitat quirúrgica, que té un percentatge de compliment de les mesures preventives més elevat que la resta de les unitats, al inici del projecte. És per aquesta raó que no sembla adequat considerar aquest model com a bo.



Gràfic 26. Efectes Aleatoris de la millora de les Unitats estimats amb el Model 3.B



Aquest gràfic mostra com el percentatge de mesures complertes millora més en les Unitats Mèdiques i les Unitats Quirúrgiques que en la resta de les unitats. Tot i aquesta diferència, no sembla adient considerar aquests efectes.

### **MILLORA DE LA TAXA DE CAIGUDES I LA SEVA RELACIÓ AMB L'ACOMPLIMENT DE LES MESURES PREVENTIVES I TENIR EL PROGRAMA DE PREVENCIÓ DE CAIGUDES**

Per fer la selecció del model més ben ajustat i passar a la interpretació d'aquest ens basarem, primerament en els valors obtinguts del DIC i el CPO. A la taula següent s'exposen aquests valors per cada un dels models estimats. Recordem que ja hem seleccionat, anteriorment, tractar la variable explicativa Percentatge de Mesures aplicades com una variable tempo-dependent.


Taula 44. Criteris de selecció entre els models plantejats per avaluar la millora de la taxa de caigudes i l'impacte de les mesures preventives

Model	DIC	CPO
<b>Model 1. Efectes Fixos</b>	3008.049	1.408016
<b>Model 2. Efectes Mixtos. Centre com efecte aleatori</b>	2851.673	---
<b>Model 2.B. Efectes Mixtos. Temps i Mesures associats a l'efecte aleatori del Centre</b>	2857.675	---
<b>Model 3. Efectes Mixtos. Unitats com efecte aleatori</b>	2933.159	---
<b>Model 3.B. Efectes Mixtos. Temps i Mesures associats a l'efecte aleatori de</b>	2933.376	---
<b>Model 4. Efectes Mixtos. Unitats anidades als Centres com a efectes aleatoris</b>	2701.335	---

Tenint en compte el criteri que com menor sigui el número del DIC i del CPO, millor és el model, a partir de la taula anterior, seleccionàrem el Model 4.


A continuació, es mostren els gràfics corresponents als efectes aleatoris associats a la taxa de caigudes de cada model estimat.

Gràfic 27. Efecte dels centres en la taxa de caigudes estimats amb el model 2




Observem que hi ha variabilitat en l'efecte dels centres referent a la taxa de caigudes. Això s'interpreta com que el valor mig de la taxa de caigudes no és homogeni entre els centres participants.

**Gràfic 28.** *Efecte dels centres en la millora de la taxa de caigudes estimats amb el model 2.B*



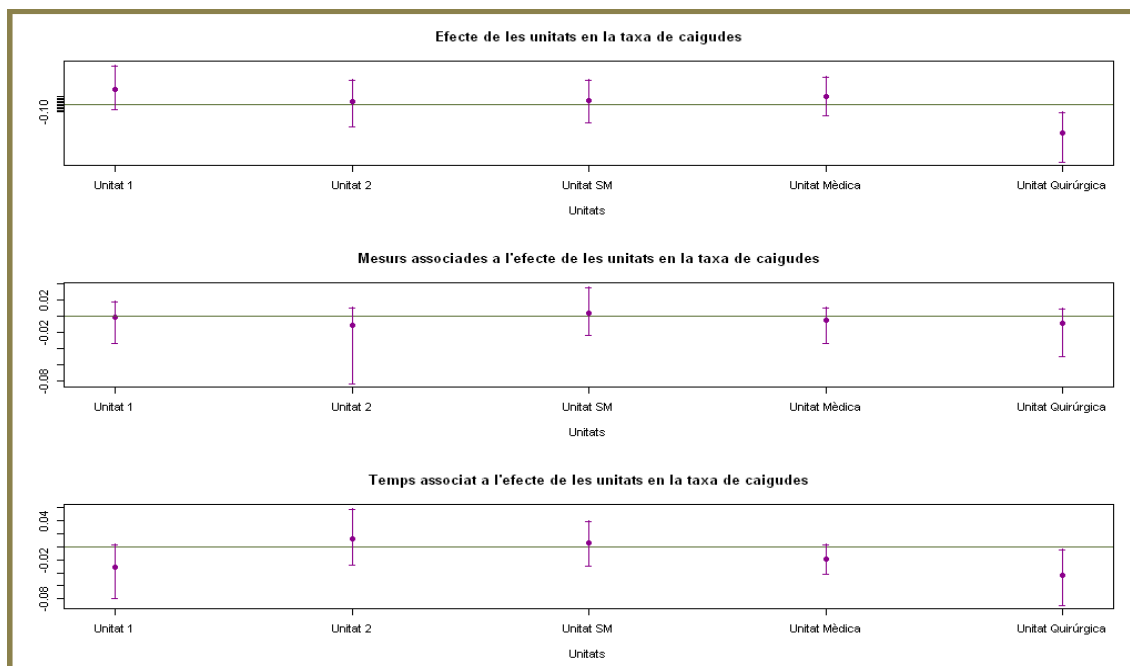
En aquest segon gràfic, observem que la variabilitat ve donada pel factor aleatori centre i que les mesures i el temps tenen efectes homogenis en tots els centres participants. No té sentit considerar aquests efectes aleatoris.

**Gràfic 29.** *Efecte de les unitats en la taxa de caigudes estimats amb el model 3*



Aquest gràfic mostra com no hi ha diferències en les taxes de caigudes entre gairebé totes les unitats, exceptuant la unitat quirúrgica que presenta una taxa inferior a la resta.

Gràfic 30. *Efecte de les unitats en la millora de la taxa de caigudes estimats amb el model 3.B*



El mateix argument que hem donat per al model 2.B, tot i que sembla que la Unitat Quirúrgica hagi disminuït més acusadament la taxa de caigudes que la resta de les unitats. Tot i això, sembla que no té sentit considerar aquests efectes aleatoris.


### 3.2.5 Interpretació dels models

Un cop seleccionats els millors models ajustats, en aquest apartat interpretarem els resultats i obtindrem les respostes a les preguntes plantejades inicialment.

### MILLORA DE L'ACOMPLIMENT DE LES MESURES PREVENTIVES

En l'apartat anterior hem vist que el millor model ajustat és aquell que té en compte l'efecte hospital  $i$ , anidat dins d'aquest, l'efecte unitat com a efectes aleatoris, i el temps i la tipologia de centre com efecte fix. A continuació es mostren els dos gràfics corresponents a les distribucions a posteriori dels coeficients estimats.

*Gràfic 31. Distribució a posteriori dels efectes fixos del model estimat per a l'avaluació de la millora de l'acompliment de les mesures preventives de les caigudes*



La primera campana que s'observa és la distribució a posteriori del coeficient associat a la quinzena avaluada. Observem que la campana es troba desplaçada cap a la dreta del, fet que indica que el percentatge de mesures preventives complertes augmenta en funció del temps, és a dir, **que els centres han millorat la implementació del conjunt de mesures preventives de les caigudes.**

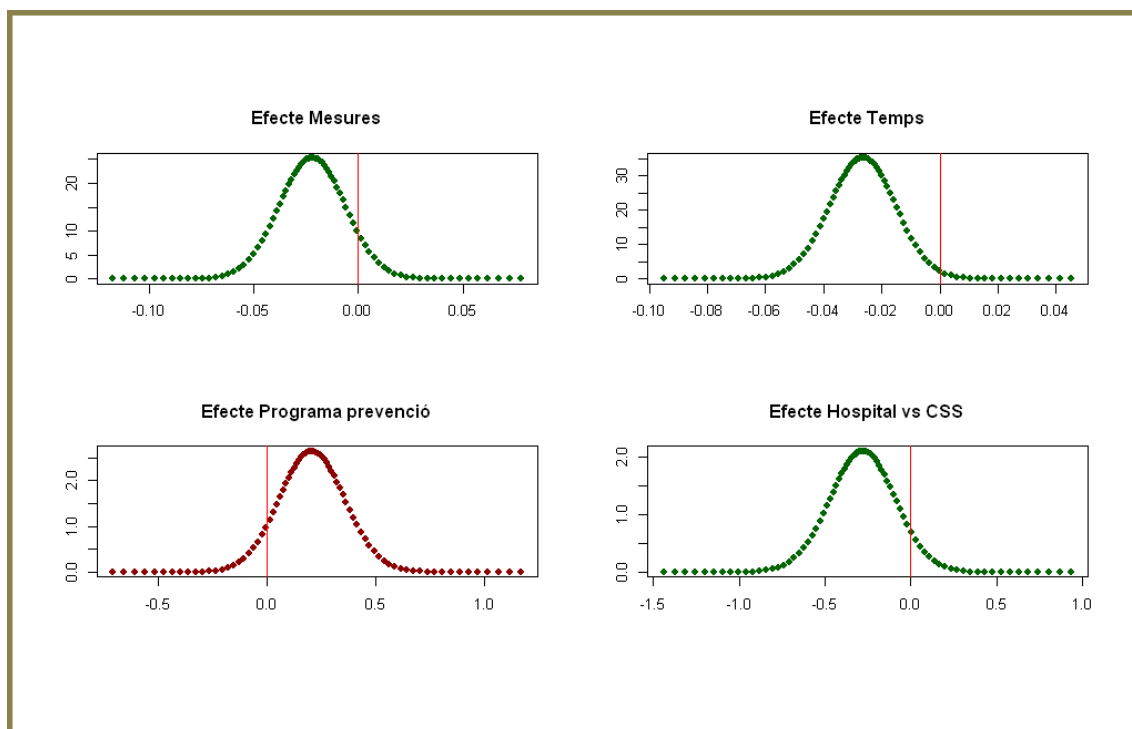
El segon gràfic correspon a la distribució a posteriori del coeficient associat a pertànyer a un hospital enlloc d'un centre sociosanitari. S'observa que la campana es troba desplaçada cap a l'esquerra del 0, fet que indica que **els hospitals apliquen un percentatge més baix de mesures preventives que els centres sociosanitaris.**

### MILLORA DE LA TAXA DE CAIGUDES I LA SEVA RELACIÓ AMB L'ACOMPLIMENT DE LES MESURES PREVENTIVES I TENIR EL PROGRAMA DE PREVENCIÓ DE CAIGUDES

Finalment, el model que interpretarem en aquesta secció és aquell que té com efectes aleatoris les unitats anidades dins dels centres, i com a efectes fixos el percentatge de mesures preventives aplicades, la quinzena en què s'han avaluat les caigudes, la presència d'un Programa de prevenció de caigudes i el tipus de centre (hospital i CSS).

A continuació es presenta un gràfic amb les distribucions a posteriori estimades per cada un dels coeficients dels efectes fixos.

*Gràfic 32. Distribució a posteriori dels efectes fixos del model estimat per a l'avaluació de la millora de la taxa de caigudes preventives i l'impacte de les mesures preventives i el Programa de Prevenció de Caigudes*



La campana superior de la columna de l'esquerra correspon a la distribució a posteriori del coeficient associat al percentatge de mesures preventives aplicades. S'observa que aquesta campana es troba desplaçada a l'esquerra del 0 i, per tant, podríem concloure que **a un major percentatge de mesures preventives aplicades s'observa una menor taxa de caigudes.**


Pel que fa a la campana que dibuixa la distribució a posteriori del coeficient associat a la quinzena avaluada, s'observa, també, que es troba desplaçada cap als números negatius. Això es pot resumir com que a l'avançar en l'estudi, la taxa de caigudes disminueix. Per tant, podríem dir **que la taxa de caigudes ha millorat respecte al inici del projecte.**

La distribució associada a l'existència d'un Programa de prevenció de caigudes es troba desplaçada cap a la dreta del 0, i això vol dir que **els centres que tenen un Programa de prevenció de caigudes han obtingut taxes de caigudes més elevades que els centres que no tenen aquest Programa.**

Per últim, la distribució a posteriori del coeficient associat a pertànyer a un hospital enlloc d'un centre sociosanitari dibuixa una campana desplaçada cap a l'esquerra del 0, fet que indica que **els hospitals apliquen han obtingut taxes de caigudes més baixes que els centres sociosanitaris.**

A partir d'aquest primer model se n'ha estimat un de segon per avaluar els efectes produïts per variables relacionades amb el Programa de prevenció de caigudes, però només amb aquells centres que en tenien. A continuació es presenten les distribucions a posteriori dels coeficients dels efectes fixos estimats en aquest últim model.

*Gràfic 33. Distribució a posteriori dels efectes fixos del model estimat per a l'avaluació de la l'impacte del contingut del Programa de Prevenció de Caigudes*



En aquest gràfic s'observa que la primera corba, que representa la distribució a posteriori de l'efecte any d'implementació del Programa es troba desplaçada cap a la dreta del 0. Aquest fet indica que **com menys temps fa que el centre disposa del Programa, taxes de caigudes més altes s'han observat.**

Al contrari passa amb la distribució a posteriori de l'efecte Valoració del Risc de caigudes dels pacients. Aquesta corba es troba desplaçada cap a l'esquerra del gràfic i, per tant, **aquells centres que el seu Programa incorpora la valoració del Risc de caigudes han observat taxes de caigudes inferiors que els centres que no incorporen aquest apartat en el Programa.**

Per últim, la tercera campana, relacionada amb la distribució a posteriori del coeficient associat a la Difusió dels anàlisis i resultats del Programa, es troba desplaçada cap a la dreta del 0 i, llavors, **aquells centres que el seu Programa incorpora la difusió dels anàlisis i resultats del Programa han observat taxes de caigudes superiors que els centres que no incorporen aquest apartat en el Programa.**





## 4 CONCLUSIONS

Amb la utilització de mètodes d'estimació Bayesians s'ha pogut experimentar aquesta corrent, cada vegada més utilitzada per els bioestadístics, en la construcció de models lineals generalitzats (d'efectes fixes, aleatoris i mixtes). Un dels avantatges que es poden destacar, observats a partir de la realització d'aquest treball, és l'obtenció de l'estimació de la distribució a posteriori dels paràmetres d'interès. Aquesta corba permet una millor interpretació dels coeficients dels models ajustats ja que, no només s'estima un valor (o interval de valors) per a cada un d'aquests com passa amb la inferència Frequentista, sinó que es pot conèixer tot el seu comportament i extreure'n conclusions basant-se amb molta més informació. Aquest treball també ha servit per comprovar que les dificultats que presentava l'estimació Bayesiana en relació al càlcul d'integrals molt complexes ha quedat resolt amb la utilització de mètodes de computació avançats realitzats pels ordinadors. Un d'aquests softwares que permet dur a terme mètodes Bayesians és l'R, gràcies a la llibreria INLA.

Una de les característiques comuns dels projectes col·laboratius és la forma que presenten les dades, estructurades en clústers (unitats clíniques, hospitals,...), ja que l'objectiu és avaluar millores que recauen en el comportament d'aquests. S'ha comprovat que, per avaluar aquestes millores, és recomanable tenir en compte en els models ajustats els efectes relacionats amb aquests clústers. És a dir, contemplar l'ajust de la variabilitat aportada per els efectes aleatoris. Hi ha diversos estudis publicats en revistes reconegudes on aquest ajust no es realitza i, per tant, els efectes fixos estimats poden presentar un biaix degut al pes excessiu que poden tenir els clústers amb més volum de casos a la mostra global.

Malgrat aquesta estructura jeràrquica, moltes vegades la recollida de dades permet obtenir variables capaces d'explicar la variabilitat aportada pels clústers, com, en el cas del projecte IMPIC, han fet les característiques dels pacients. És per aquesta raó que no es poden deixar de banda els models més senzills que, ben ajustats per les variables explicatives, eliminen els efectes aleatoris. En aquest treball s'ha pogut validar la **metodologia gradual** que consisteix en ajustar un model inicial d'efectes fixes i anar-hi afegint, jeràrquicament, els efectes aleatoris dels clústers. La finalitat d'aquesta metodologia és la de considerar tot el ventall possible de models ajustats i, posteriorment, seleccionar el que millor s'adapti a les dades. Coneixent i

entenent tots aquests models es poden identificar patrons individuals de comportament dels clústers, que aporten informació al procés de millora, tot i que no s'acabin seleccionant com a models finals.

Un cop finalitzat aquest projecte amb la posada en pràctica de la metodologia per avaluar millores de l'atenció sanitària en projectes col·laboratius, s'han arribat a les següents conclusions:

- En el projecte IMPIC s'ha observat que la variable a modelar és molt depenent de les característiques dels pacients i, per tant, la variabilitat aportada pels hospitals no és significativa. En aquest cas, la metodologia ens ha donat com a resultat bo un model on els efectes aleatoris no tenien significància.
- Continuant amb el mateix cas, a l'hora de seleccionar el model adequat, en dues ocasions ens hem trobat que el criteri del DIC i del CPO no corresponien amb el de la distribució a posteriori dels efectes aleatoris. Això es deu al excessiu pes d'algun clúster que esbiaixa els valors del DIC i CPO. Per aquesta raó, seguir el procediment gradual de la metodologia ens ha resultat útil ja que hem entès, model a model, tots els casos a tenir en compte.
- En el projecte de PREVENCIÓ DE CAIGUDES, on la recollida de dades no va permetre considerar variables de tipologia de pacient, la metodologia ens ha donat com a resultat un model amb efectes fixes, ja que els clústers, en aquest cas, si que aportaven variabilitat. Així doncs, hem observat com aplicant la mateixa metodologia en dos casos amb dades diferents, ens donen models bons diferents.
- També en el mateix projecte, ja que les dades es trobaven estructurades de forma jeràrquica de dos nivells, la metodologia ens ha permès conèixer variabilitats en clústers que finalment no hem seleccionat per avaluar la millora, però que aporten informació extra en el procés.
- En el projecte CAIGUDES s'ha observat que la variable mesures preventives era depenent del temps, és a dir, estava avaluada de tal manera que permetia estimar el nivell d'aplicació d'aquestes en un interval de temps determinat. Segons s'ha pogut consultar en diferent bibliografia, aquest tipus de variable ha de tractar-se tenint en compte aquesta dependència temporal. Després de comprar el model sense tenir i

tenint en compte la temporalitat mitjançant el producte entre la variable d'interès i el temps, s'ha pogut confirmar que aquest tractament ajusta un millor model.



## 5 REFERÈNCIES BIBLIOGRÀFIQUES

**Arnau J., Balluerka N.** (2004). Análisis de datos longitudinales y de curvas de crecimiento. Enfoque clásico y propuestas actuales. *Psicothema*. Vol 16. nº 1. pp. 156-162.  
<http://www.psicothema.com/pdf/1175.pdf>

**Beyersmann J., Kneib T., Shumacher M., Gastmeier P.** (2009). Nosocomial Infection of Stay and Time-Dependent Bias. *Infection control and hospital epidemiology*. Vol. 30. Nº 3.

**Beyersmann J., Wolkewitz M., Shumacher M.** (2008). The impact of time-dependent bias in proportional hazards modelling. *Statistics in Medicine*. 27:6439-6454.

**Jos W.R. Twisk** (2006). *Applies Multilevel Analysis*. Versión publicada en 2010.

**Martino S., Rue H.** (2010). Case Studies in Bayesian Computation using INLA.  
<http://www.math.ntnu.no/~hrue/r-inla.org/papers/martino-rue-book.pdf>

**Miguel Ángel Martínez Beneito, Marc Marí Dell'Olmo** (2011). Curso sobre análisis geográfico de datos en áreas pequeñas en ciencias de la salud. Material didàctic.

**Marc Sáez** (2011). *Introduction to Bayesian Inference*. Apunts elaborats pel curs Spatial Analysis in Epidemiology, Villa Gualino, Torino.



## Annex - SINTAXIS R

### IMPIC

```
## Descriptiu
colon<-impic[which(impic$TQColon_bona=="Sí"),]
attach(colon)
recte<-impic[which(impic$TQRecto_bona=="Sí"),]
detach(colon)
attach(recte)

#####
media<-function(x) return(mean(x,na.rm=T))####
#####

# Distribució de les intervencions quirúrgiques en el hospitals

par(oma=c(2,1,2,1))
barplot(table(impic$IdHospital),names=1:24,col="gray85",main=paste("Distribució de les intervencions quirúrgiques",sep="\n", "en els hospitals participants"),cex.main=1.5,xlab="Hospitals Participants",ylab="Nº d'intervencions quirúrgiques")
box("outer",lwd=10,col="lightgoldenrod4")

summary(table(impic$IdHospital)[,])

# COLON

colon<-impic[which(impic$TQColon_bona=="Sí"),]
attach(colon)

## IEQ Transversal

prop.table(table(IEQ_I))
prop.table(table(IEQ_OC))

ieq_i<-as.numeric(IEQ_I)-1
ieq_hospi.i<-
aggregate(c(ieq_i),by=list(Hospital=IdHospital),FUN=media)
ieq_oc<-as.numeric(IEQ_OC)-1
ieq_hospi.oc<-
aggregate(c(ieq_oc),by=list(Hospital=IdHospital),FUN=media)

par(mfrow=c(1,2),oma=c(0,1,2,1))
stripchart(ieq_hospi.i$x,method="jitter",ylab="Taxa d'infecció",vertical=T,pch=16,main=paste("Distribució de la infecció incisional",sep="\n", "en els hospitals participants"),col="darkred",ylim=c(0,0.364))
boxplot(ieq_hospi.i$x,outline=F,add=T)
stripchart(ieq_hospi.oc$x,method="jitter",ylab="Taxa d'infecció",vertical=T,pch=16,main=paste("Distribució de la infecció òrgano-cavitària",sep="\n", "en els hospitals participants"),col="olivedrab2",ylim=c(0,0.364))
boxplot(ieq_hospi.oc$x,outline=F,add=T)
box("outer",lwd=10,col="lightgoldenrod4")
```



```

## Compliment de les mesures

prop.table(table(AcomplimentMesuresTotes_2))
prop.table(table(AcomplimentMesuresTotesOC))

mesures<-as.numeric(AcomplimentMesuresTotes_2)-1
mesures_hospi<-
aggregate(c(mesures),by=list(Hospital=IdHospital),FUN=media)
mesures.oc<-as.numeric(AcomplimentMesuresTotesOC)-1
mesures_hospi.oc<-
aggregate(c(mesures.oc),by=list(Hospital=IdHospital),FUN=media)

par(mfrow=c(1,2),oma=c(0,2,2,1))
stripchart(mesures_hospi$x*100,method="jitter",ylab="Percentatge
d'acompliment",vertical=T,pch=16,main=paste("Distribució de
l'acompliment",sep="\n","de les mesures associades a la IEQ I","en els
hospitals participants"),col="darkred",ylim=c(0,100))
boxplot(mesures_hospi$x*100,outer=F,add=T)
stripchart(mesures_hospi.oc$x*100,method="jitter",ylab="Percentatge
d'acompliment",vertical=T,pch=16,main=paste("Distribució de
l'acompliment",sep="\n","de les mesures associades a la IEQ OC","en
els hospitals participants"),col="olivedrab2",ylim=c(0,100))
boxplot(mesures_hospi.oc$x*100,outline=F,add=T)
box("outer",lwd=10,col="lightgoldenrod4")

## Evolució

ieq_hospi_mes<-
aggregate(c(ieq_i),by=list(Hospital=IdHospital, Temps=MES_ESTUDI),FUN=m
edia)
mesures_hospi_mes<-
aggregate(c(mesures),by=list(Hospital=IdHospital, Temps=MES_ESTUDI),FUN
=media)

ieqoc_hospi_mes<-
aggregate(c(ieq_oc),by=list(Hospital=IdHospital, Temps=MES_ESTUDI),FUN=
media)
mesuresoc_hospi_mes<-
aggregate(c(mesures.oc),by=list(Hospital=IdHospital, Temps=MES_ESTUDI),
FUN=media)

m.ieq<-rep(NA,9)
m.mesures<-rep(NA,9)
m.ieqoc<-rep(NA,9)
m.mesuresoc<-rep(NA,9)
for(i in 1:9){
  m.ieq[i]<-
media(ieq_hospi_mes[which(ieq_hospi_mes$Temps==i),"x"])
  m.mesures[i]<-
media(mesures_hospi_mes[which(mesures_hospi_mes$Temps==i),"x"])
  m.ieqoc[i]<-
media(ieqoc_hospi_mes[which(ieqoc_hospi_mes$Temps==i),"x"])
  m.mesuresoc[i]<-
media(mesuresoc_hospi_mes[which(mesuresoc_hospi_mes$Temps==i),"x"])
}

par(mfrow=c(1,2),oma=c(0,2,2,1))

```

```

plot(1:9,m.ieq,axes=F,xlab="Mes",ylab="Proporció",main=paste("Evolució
de la infecció I",sep="\n","i l'acompliment de les
mesures"),pch=16,ylim=c(0,1))
lines(1:9,m.ieq,lty=3,col="darkred",lwd=4)
points(1:9,m.ieq,pch=19,col="darkred")
lines(1:9,m.mesures,lty=3,col="olivedrab2",lwd=4)
points(1:9,m.mesures,pch=19,col="olivedrab2")
axis(1,1:9)
axis(2,seq(0,1,.1))
box("outer",lwd=10,col="lightgoldenrod4")
legend(3,0.4,c("Infecció I","Acomplimet
Mesures"),col=c("darkred","olivedrab2"),lty=c(3,3),lwd=3,cex=0.75,bty=
"n")
box("outer",lwd=10)
plot(1:9,m.ieqoc,axes=F,xlab="Mes",ylab="Proporció",main=paste("Evolució
de la infecció OC",sep="\n","i l'acompliment de les
mesures"),pch=16,ylim=c(0,1))
lines(1:9,m.ieqoc,lty=3,col="orange",lwd=4)
points(1:9,m.ieqoc,pch=19,col="orange")
lines(1:9,m.mesuresoc,lty=3,col="steelblue4",lwd=4)
points(1:9,m.mesuresoc,pch=19,col="steelblue4")
axis(1,1:9)
axis(2,seq(0,1,.1))
legend(3,0.4,c("Infecció OC","Acomplimet
Mesures"),col=c("orange","steelblue4"),lty=c(3,3),lwd=3,cex=0.75,bty="
n")
box("outer",lwd=10,col="lightgoldenrod4")

```

```
# RECTE
```

```
recte<-impic[which(impic$TQRecto_bona=="Sí"),]
detach(colon)
attach(recte)
```

```
## IEQ Transversal
```

```
prop.table(table(IEQ_I))
prop.table(table(IEQ_OC))
```

```
ieq_i<-as.numeric(IEQ_I)-1
ieq_hospi.i<-
aggregate(c(ieq_i),by=list(Hospital=IdHospital),FUN=media)
ieq_oc<-as.numeric(IEQ_OC)-1
ieq_hospi.oc<-
aggregate(c(ieq_oc),by=list(Hospital=IdHospital),FUN=media)
```

```
par(mfrow=c(1,2),oma=c(0,1,2,1))
stripchart(ieq_hospi.i$x,method="jitter",ylab="Taxa
d'infecció",vertical=T,pch=16,main=paste("Distribució de la infecció
incisional",sep="\n","en els hospitals
participants"),col="darkred",ylim=c(0,0.5))
boxplot(ieq_hospi.i$x,outline=F,add=T)
stripchart(ieq_hospi.oc$x,method="jitter",ylab="Taxa
d'infecció",vertical=T,pch=16,main=paste("Distribució de la infecció
òrgano-cavitària",sep="\n","en els hospitals
participants"),col="olivedrab2",ylim=c(0,0.5))
```

```

boxplot(ieq_hospi.oc$x, outline=F, add=T)
box("outer", lwd=10, col="lightgoldenrod4")

## Compliment de les mesures

prop.table(table(AcomplimentMesuresTotes_2))
prop.table(table(AcomplimentMesuresTotesOC))

mesures<-as.numeric(AcomplimentMesuresTotes_2)-1
mesures_hospi<-
aggregate(c(mesures), by=list(Hospital=IdHospital), FUN=media)
mesures.oc<-as.numeric(AcomplimentMesuresTotesOC)-1
mesures_hospi.oc<-
aggregate(c(mesures.oc), by=list(Hospital=IdHospital), FUN=media)

par(mfrow=c(1,2), oma=c(0,2,2,1))
stripchart(mesures_hospi$x*100, method="jitter", ylab="Percentatge
d'acompliment", vertical=T, pch=16, main=paste("Distribució de
l'acompliment", sep="\n", "de les mesures associades a la IEQ I", "en els
hospitals participants"), col="darkred", ylim=c(0,100))
boxplot(mesures_hospi$x*100, outer=F, add=T)
stripchart(mesures_hospi.oc$x*100, method="jitter", ylab="Percentatge
d'acompliment", vertical=T, pch=16, main=paste("Distribució de
l'acompliment", sep="\n", "de les mesures associades a la IEQ OC", "en
els hospitals participants"), col="olivedrab2", ylim=c(0,100))
boxplot(mesures_hospi.oc$x*100, outline=F, add=T)
box("outer", lwd=10, col="lightgoldenrod4")

## Evolució

ieq_hospi_mes<-
aggregate(c(ieq_i), by=list(Hospital=IdHospital, Temps=MES_ESTUDI), FUN=m
edia)
mesures_hospi_mes<-
aggregate(c(mesures), by=list(Hospital=IdHospital, Temps=MES_ESTUDI), FUN
=media)

ieqoc_hospi_mes<-
aggregate(c(ieq_oc), by=list(Hospital=IdHospital, Temps=MES_ESTUDI), FUN=
media)
mesuresoc_hospi_mes<-
aggregate(c(mesures.oc), by=list(Hospital=IdHospital, Temps=MES_ESTUDI),
FUN=media)

m.ieq<-rep(NA,9)
m.mesures<-rep(NA,9)
m.ieqoc<-rep(NA,9)
m.mesuresoc<-rep(NA,9)
for(i in 1:9){
  m.ieq[i]<-
media(ieq_hospi_mes[which(ieq_hospi_mes$Temps==i), "x"])
  m.mesures[i]<-
media(mesures_hospi_mes[which(mesures_hospi_mes$Temps==i), "x"])
  m.ieqoc[i]<-
media(ieqoc_hospi_mes[which(ieqoc_hospi_mes$Temps==i), "x"])
  m.mesuresoc[i]<-
media(mesuresoc_hospi_mes[which(mesuresoc_hospi_mes$Temps==i), "x"])
}

```

```

}

par(mfrow=c(1,2),oma=c(0,2,2,1))
plot(1:9,m.ieq,axes=F,xlab="Mes",ylab="Proporció",main=paste("Evolució
de la infecció I",sep="\n","i l'acompliment de les
mesures"),pch=16,ylim=c(0,1))
lines(1:9,m.ieq,lty=3,col="darkred",lwd=4)
points(1:9,m.ieq,pch=19,col="darkred")
lines(1:9,m.mesures,lty=3,col="olivedrab2",lwd=4)
points(1:9,m.mesures,pch=19,col="olivedrab2")
axis(1,1:9)
axis(2,seq(0,1,.1))
box("outer",lwd=10,col="lightgoldenrod4")
legend(3,0.4,c("Infecció I","Acomplimet
Mesures"),col=c("darkred","olivedrab2"),lty=c(3,3),lwd=3,cex=0.75,bty=
"n")
box("outer",lwd=10)
plot(1:9,m.ieqoc,axes=F,xlab="Mes",ylab="Proporció",main=paste("Evolució
de la infecció OC",sep="\n","i l'acompliment de les
mesures"),pch=16,ylim=c(0,1))
lines(1:9,m.ieqoc,lty=3,col="orange",lwd=4)
points(1:9,m.ieqoc,pch=19,col="orange")
lines(1:9,m.mesuresoc,lty=3,col="steelblue4",lwd=4)
points(1:9,m.mesuresoc,pch=19,col="steelblue4")
axis(1,1:9)
axis(2,seq(0,1,.1))
legend(3,0.4,c("Infecció OC","Acomplimet
Mesures"),col=c("orange","steelblue4"),lty=c(3,3),lwd=3,cex=0.75,bty=
"n")
box("outer",lwd=10,col="lightgoldenrod4")

```

```

#####
####

```

#### ESTIMACIÓ DELS MODELS

```

#####
####

```

```

library(INLA)
inla.upgrade()

## Acompliment de les mesures preventives.

## Fixes

explicativa<-as.numeric(AcomplimentMesuresTotes_2)-1
temps<-MES_ESTUDI
hospital<- IdHospital
hospital2<- hospital
Datos<-data.frame(explicativa,temps,hospital,hospital2)

formula = explicativa~ temps
resultat.1 = inla(formula, family="binomial", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
),data=Datos,verbose=TRUE)

```

```

summary(resultat.1)
exp(resultat.1$summary.fixed)

resultat.1$dic$dic

-mean(log(resultat.1$cpo),na.rm=T)
-mean(log(resultat.1$cpo[resultat.1$cpo>0]),na.rm=T)

## Mixtes

formula = explicativa~ temps+f(hospital2,model="iid")
resultat.2 = inla(formula, family="binomial", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
),data=Datos,verbose=TRUE)

summary(resultat.2)
exp(resultat.2$summary.fixed)

resultat.2$dic$dic

-mean(log(resultat.2$cpo),na.rm=T)
-mean(log(resultat.2$cpo[resultat.2$cpo>0]),na.rm=T)

sample.mesures.h1 =
inla.rmarginal(1000,resultat.2$marginals.random$hospital2[names(result
at.2$marginals.random$hospital2)[1]][[1]])
sample.mesures.h2 =
inla.rmarginal(1000,resultat.2$marginals.random$hospital2[names(result
at.2$marginals.random$hospital2)[2]][[1]])
sample.mesures.h3 =
inla.rmarginal(1000,resultat.2$marginals.random$hospital2[names(result
at.2$marginals.random$hospital2)[3]][[1]])
sample.mesures.h4 =
inla.rmarginal(1000,resultat.2$marginals.random$hospital2[names(result
at.2$marginals.random$hospital2)[4]][[1]])
sample.mesures.h5 =
inla.rmarginal(1000,resultat.2$marginals.random$hospital2[names(result
at.2$marginals.random$hospital2)[5]][[1]])
sample.mesures.h6 =
inla.rmarginal(1000,resultat.2$marginals.random$hospital2[names(result
at.2$marginals.random$hospital2)[6]][[1]])
sample.mesures.h7 =
inla.rmarginal(1000,resultat.2$marginals.random$hospital2[names(result
at.2$marginals.random$hospital2)[7]][[1]])
sample.mesures.h8 =
inla.rmarginal(1000,resultat.2$marginals.random$hospital2[names(result
at.2$marginals.random$hospital2)[8]][[1]])
sample.mesures.h9 =
inla.rmarginal(1000,resultat.2$marginals.random$hospital2[names(result
at.2$marginals.random$hospital2)[9]][[1]])
sample.mesures.h10 =
inla.rmarginal(1000,resultat.2$marginals.random$hospital2[names(result
at.2$marginals.random$hospital2)[10]][[1]])
sample.mesures.h11 =
inla.rmarginal(1000,resultat.2$marginals.random$hospital2[names(result
at.2$marginals.random$hospital2)[11]][[1]])

```

```

sample.mesures.h12 =
inla.rmarginal(1000,resultat.2$marginals.random$hospital2[names(result
at.2$marginals.random$hospital2)[12]][[1]])
sample.mesures.h13 =
inla.rmarginal(1000,resultat.2$marginals.random$hospital2[names(result
at.2$marginals.random$hospital2)[13]][[1]])
sample.mesures.h14 =
inla.rmarginal(1000,resultat.2$marginals.random$hospital2[names(result
at.2$marginals.random$hospital2)[14]][[1]])
sample.mesures.h15 =
inla.rmarginal(1000,resultat.2$marginals.random$hospital2[names(result
at.2$marginals.random$hospital2)[15]][[1]])
sample.mesures.h16 =
inla.rmarginal(1000,resultat.2$marginals.random$hospital2[names(result
at.2$marginals.random$hospital2)[16]][[1]])
sample.mesures.h17 =
inla.rmarginal(1000,resultat.2$marginals.random$hospital2[names(result
at.2$marginals.random$hospital2)[17]][[1]])
sample.mesures.h18 =
inla.rmarginal(1000,resultat.2$marginals.random$hospital2[names(result
at.2$marginals.random$hospital2)[18]][[1]])
sample.mesures.h19 =
inla.rmarginal(1000,resultat.2$marginals.random$hospital2[names(result
at.2$marginals.random$hospital2)[19]][[1]])
sample.mesures.h20 =
inla.rmarginal(1000,resultat.2$marginals.random$hospital2[names(result
at.2$marginals.random$hospital2)[20]][[1]])
sample.mesures.h21 =
inla.rmarginal(1000,resultat.2$marginals.random$hospital2[names(result
at.2$marginals.random$hospital2)[21]][[1]])
sample.mesures.h22 =
inla.rmarginal(1000,resultat.2$marginals.random$hospital2[names(result
at.2$marginals.random$hospital2)[22]][[1]])
sample.mesures.h23 =
inla.rmarginal(1000,resultat.2$marginals.random$hospital2[names(result
at.2$marginals.random$hospital2)[23]][[1]])

```

## Efecte de les caigudes per cada hospital

```

efecte.mesures.h1<-(sample.mesures.h1)
efecte.mesures.h2<-(sample.mesures.h2)
efecte.mesures.h3<-(sample.mesures.h3)
efecte.mesures.h4<-(sample.mesures.h4)
efecte.mesures.h5<-(sample.mesures.h5)
efecte.mesures.h6<-(sample.mesures.h6)
efecte.mesures.h7<-(sample.mesures.h7)
efecte.mesures.h8<-(sample.mesures.h8)
efecte.mesures.h9<-(sample.mesures.h9)
efecte.mesures.h10<-(sample.mesures.h10)
efecte.mesures.h11<-(sample.mesures.h11)
efecte.mesures.h12<-(sample.mesures.h12)
efecte.mesures.h13<-(sample.mesures.h13)
efecte.mesures.h14<-(sample.mesures.h14)
efecte.mesures.h15<-(sample.mesures.h15)
efecte.mesures.h16<-(sample.mesures.h16)
efecte.mesures.h17<-(sample.mesures.h17)
efecte.mesures.h18<-(sample.mesures.h18)
efecte.mesures.h19<-(sample.mesures.h19)
efecte.mesures.h20<-(sample.mesures.h20)
efecte.mesures.h21<-(sample.mesures.h21)
efecte.mesures.h22<-(sample.mesures.h22)

```

```

efecte.mesures.h23<-(sample.mesures.h23)

mitjana<-
c(mean(efecte.mesures.h1),mean(efecte.mesures.h2),mean(efecte.mesures.
h3),mean(efecte.mesures.h4),mean(efecte.mesures.h5),mean(efecte.mesure
s.h6),
mean(efecte.mesures.h7),mean(efecte.mesures.h8),mean(efecte.mesures.h9
),mean(efecte.mesures.h10),mean(efecte.mesures.h11),mean(efecte.mesure
s.h12),
mean(efecte.mesures.h13),mean(efecte.mesures.h14),mean(efecte.mesures.
h15),mean(efecte.mesures.h16),mean(efecte.mesures.h17),mean(efecte.mes
ures.h18),
mean(efecte.mesures.h19),mean(efecte.mesures.h20),mean(efecte.mesures.
h21),mean(efecte.mesures.h22),mean(efecte.mesures.h23))

ic.inf<-
c(quantile(efecte.mesures.h1,0.025),quantile(efecte.mesures.h2,0.025),
quantile(efecte.mesures.h3,0.025),quantile(efecte.mesures.h4,0.025),qu
antile(efecte.mesures.h5,0.025),quantile(efecte.mesures.h6,0.025),
quantile(efecte.mesures.h7,0.025),quantile(efecte.mesures.h8,0.025),qu
antile(efecte.mesures.h9,0.025),quantile(efecte.mesures.h10,0.025),qua
ntile(efecte.mesures.h11,0.025),quantile(efecte.mesures.h12,0.025),
quantile(efecte.mesures.h13,0.025),quantile(efecte.mesures.h14,0.025),
quantile(efecte.mesures.h15,0.025),quantile(efecte.mesures.h16,0.025),
quantile(efecte.mesures.h17,0.025),quantile(efecte.mesures.h18,0.025),
quantile(efecte.mesures.h19,0.025),quantile(efecte.mesures.h20,0.025),
quantile(efecte.mesures.h21,0.025),quantile(efecte.mesures.h22,0.025),
quantile(efecte.mesures.h23,0.025))

ic.sup<-
c(quantile(efecte.mesures.h1,0.975),quantile(efecte.mesures.h2,0.975),
quantile(efecte.mesures.h3,0.975),quantile(efecte.mesures.h4,0.975),qu
antile(efecte.mesures.h5,0.975),quantile(efecte.mesures.h6,0.975),
quantile(efecte.mesures.h7,0.975),quantile(efecte.mesures.h8,0.975),qu
antile(efecte.mesures.h9,0.975),quantile(efecte.mesures.h10,0.975),qua
ntile(efecte.mesures.h11,0.975),quantile(efecte.mesures.h12,0.975),
quantile(efecte.mesures.h13,0.975),quantile(efecte.mesures.h14,0.975),
quantile(efecte.mesures.h15,0.975),quantile(efecte.mesures.h16,0.975),
quantile(efecte.mesures.h17,0.975),quantile(efecte.mesures.h18,0.975),
quantile(efecte.mesures.h19,0.975),quantile(efecte.mesures.h20,0.975),
quantile(efecte.mesures.h21,0.975),quantile(efecte.mesures.h22,0.975),
quantile(efecte.mesures.h23,0.975))

par(oma=c(8,1,8,1),mfrow=c(1,3))
plot(resultat.2$marginals.fixed$(Intercept)[,1],resultat.2$marginals
.fixed$(Intercept)[,2],xlab="",ylab="",main="Intercept",pch=19)
abline(v=0,col="red")
plot(resultat.2$marginals.fixed$temps[,1],resultat.2$marginals.fixed
$temps[,2],xlab="",ylab="",main="Efecte del Mes
d'estudi",col="darkgreen",pch=19)
abline(v=0,col="red")
plot(1:23,mitjana,ylim=c(min(ic.inf),max(ic.sup)),xlim=c(0.95,23.05),p
ch=19,main=paste("Coeficients associats",sep="\n","a l'acompliment
dels hospitals"),xlab="Hospitals",ylab="",col="darkgreen")
points(1:23,ic.inf,pch=95,col="darkgreen")
points(1:23,ic.sup,pch=95,col="darkgreen")
#axis(1,seq(1:23))
abline(h=0,col="darkred")
for (i in 1:23){
  lines(c(i,i),c(ic.inf[i],ic.sup[i]),col="darkgreen")
}

```

```

}
box("outer",lwd=10,col="lightgoldenrod4")

#####
####
formula = explicativa~+f(hospital2,model="iid")

resultat.2 = inla(formula, family="binomial", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
),data=Datos,verbose=TRUE)

summary(resultat.2)
exp(resultat.2$summary.fixed)

resultat.2$dic$dic

-mean(log(resultat.2$cpo),na.rm=T)
-mean(log(resultat.2$cpo[resultat.2$cpo>0]),na.rm=T)

par(oma=c(2,1,2,1))
plot(1:23,mitjana,ylim=c(min(ic.inf),max(ic.sup)),xlim=c(0.95,23.05),p
ch=19,main="Coeficients associats a la millora de l'acompliment dels
hospitals. MODEL 4",xlab="Hospitals",ylab="",col="darkgreen")
points(1:23,ic.inf,pch=95,col="darkgreen")
points(1:23,ic.sup,pch=95,col="darkgreen")
axis(1,seq(1:23))
abline(h=0,col="red")
for (i in 1:23){
  lines(c(i,i),c(ic.inf[i],ic.sup[i]),col="darkgreen")
}
box("outer",lwd=10,col="lightgoldenrod4")

#####
#####

## COLON. INCISIONAL.

#### MODEL 1: EFECTE VARIABLES PACIENT (Edat, sexe, imc)

infeccio<-as.numeric(IEQ_I)-1
temps<-MES_ESTUDI
edat<-Edad
sexe<-as.numeric(Genero)-1 ## 0 = Home/ 1 = Dona
imc<-IMC
hospital<- IdHospital
Datos<-data.frame(hospital=hospital,infeccio, edat=edat, sexe=sexe,
imc=imc)
formula = infeccio~ f(hospital,model="iid")+sexe
formula = infeccio~ sexe

```



```

resultat.1 = inla(formula, family="binomial", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
), data=Datos,verbose=T)

summary(resultat.1)

resultat.1$dic$dic

-mean(log(resultat.1$cpo),na.rm=T)
-mean(log(resultat.1$cpo[resultat.1$cpo>0]),na.rm=T)

plot(resultat.1$marginals.fixed$"sexe"[,1],resultat.1$marginals.fixed$
"sexe"[,2],xlab="",ylab="",main="Efecte del sexe")
abline(v=0,col="red")

#### MODEL 2: EFECTE VARIABLES RISC DE PACIENT (Charlson, ASA, NNIS,
Glucèmia)
Datos<-data.frame(hospital=hospital,infecio, edat=edat, sexe=sexe,
imc=imc)
charlson<-as.numeric(AntCharlson_cat)-1 ## 0 = <2/ 1 = >2
asa<-as.numeric(ASA_cat)-1 ## 0 = 1-2/ 1 = 3-4
nnis<-as.numeric(RiesgoIEQ_Cat)-1 ## 0 = -1/0 / 1 = 1/2/3
glucemia<-as.numeric(Glucemia_cat)-1 ## 0 = <200/ 1 = >200
Datos<-data.frame(Datos, charlson, asa, nnis, glucemia)
formula = infecio~ f(hospital,model="iid")+sexe+glucemia+nnis
formula = infecio~ sexe+glucemia+nnis

resultat.2 = inla(formula, family="binomial", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
), data=Datos,verbose=T)

summary(resultat.2)

resultat.2$dic$dic
-mean(log(resultat.2$cpo),na.rm=T)
-mean(log(resultat.2$cpo[resultat.2$cpo>0]),na.rm=T)

par(mfrow=c(3,1))
plot(resultat.2$marginals.fixed$"sexe"[,1],resultat.2$marginals.fixed$
"sexe"[,2],xlab="",ylab="",main="Efecte Sexe (Dona)")
abline(v=0,col="red")
plot(resultat.2$marginals.fixed$"nnis"[,1],resultat.2$marginals.fixed$
"nnis"[,2],xlab="",ylab="",main="Efecte NNIS (Risc Alt)")
abline(v=0,col="red")
plot(resultat.2$marginals.fixed$"glucemia"[,1],resultat.2$marginals.fi
xed$"glucemia"[,2],xlab="",ylab="",main="Efecte Glucemia (> 200
mg/dL)")
abline(v=0,col="red")
box("outer",lwd=5)

#### MODEL 4: EFECTE MESURES, TEMPS

Datos<-data.frame(hospital=hospital,infecio, edat=edat, sexe=sexe,
imc=imc,temps)
Datos<-data.frame(Datos, charlson, asa, nnis, glucemia)

explicativa<-as.numeric(AcomplimentMesuresTotes_2)-1
nnis2<-nnis

```

```

explicativa2<-explicativa
Datos<-data.frame(Datos, explicativa,explicativa2,nnis2)

formula = infeccio~
f(hospital,model="iid")+nnis+sexe+glucemia+explicativa*temps+nnis2:exp
licativa2
formula = infeccio~
sexe+glucemia+nnis+explicativa*temps+nnis2:explicativa2

resultat.4 = inla(formula, family="binomial", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
), data=Datos,verbose=T)

summary(resultat.4)

resultat.4$dic$dic
-mean(log(resultat.4$cpo),na.rm=T)
-mean(log(resultat.4$cpo[resultat.4$cpo>0]),na.rm=T)

par(mfrow=c(2,4))
#plot(resultat.4$marginals.fixed$(Intercept)[,1],resultat.4$marginal
s.fixed$(Intercept)[,2],xlab="",ylab="",main="Intercept")
#abline(v=0,col="red")
plot(resultat.4$marginals.fixed$sexe[,1],resultat.4$marginals.fixed$
sexe[,2],xlab="",ylab="",main="Efecte Sexe
(Dona)",col="darkred",pch=19)
abline(v=0,col="red")
plot(resultat.4$marginals.fixed$nnis[,1],resultat.4$marginals.fixed$
nnis[,2],xlab="",ylab="",main="Efecte NNIS (Risc
Alt)",col="darkred",pch=19)
abline(v=0,col="red")
plot(resultat.4$marginals.fixed$glucemia[,1],resultat.4$marginals.fi
xed$glucemia[,2],xlab="",ylab="",main="Efecte Glucemia (> 200
mg/dL)",col="darkred",pch=19)
abline(v=0,col="red")
plot(resultat.4$marginals.fixed$explicativa[,1],resultat.4$marginals
.fixed$explicativa[,2],xlab="",ylab="",main="Efecte Mesures
(Acompliment)",pch=19)
abline(v=0,col="red")
plot(resultat.4$marginals.fixed$temps[,1],resultat.4$marginals.fixed
$temps[,2],xlab="",ylab="",main="Efecte Mes",col="darkgreen",pch=19)
abline(v=0,col="red")
plot(resultat.4$marginals.fixed$explicativa:temps[,1],resultat.4$mar
ginals.fixed$explicativa:temps[,2],xlab="",ylab="",main="Efecte
Mesures:Mes",col="darkred",pch=19)
abline(v=0,col="red")
plot(resultat.4$marginals.fixed$nnis2:explicativa2[,1],resultat.4$ma
rginals.fixed$nnis2:explicativa2[,2],xlab="",ylab="",main="Efecte
Mesures:NNIS",col="darkred",pch=19)
abline(v=0,col="red")
box("outer",lwd=10,col="lightgoldenrod4")

## Efecte aleatori

# Generem una mostra aleatoria de l'efecte aleatori de les mesures per
cada hospital

```

```

sample.mesures.h1 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[1]][[1]])
sample.mesures.h2 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[2]][[1]])
sample.mesures.h3 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[3]][[1]])
sample.mesures.h4 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[4]][[1]])
sample.mesures.h5 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[5]][[1]])
sample.mesures.h6 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[6]][[1]])
sample.mesures.h7 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[7]][[1]])
sample.mesures.h8 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[8]][[1]])
sample.mesures.h9 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[9]][[1]])
sample.mesures.h10 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[10]][[1]])
sample.mesures.h11 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[11]][[1]])
sample.mesures.h12 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[12]][[1]])
sample.mesures.h13 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[13]][[1]])
sample.mesures.h14 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[14]][[1]])
sample.mesures.h15 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[15]][[1]])
sample.mesures.h16 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[16]][[1]])
sample.mesures.h17 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[17]][[1]])
sample.mesures.h18 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[18]][[1]])
sample.mesures.h19 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[19]][[1]])
sample.mesures.h20 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[20]][[1]])

```

```

sample.mesures.h21 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[21]][[1]])
sample.mesures.h22 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[22]][[1]])
sample.mesures.h23 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[23]][[1]])

```

```

## Efecte de les caigudes per cada hospital

```

```

efecte.mesures.h1<-(sample.mesures.h1)
efecte.mesures.h2<-(sample.mesures.h2)
efecte.mesures.h3<-(sample.mesures.h3)
efecte.mesures.h4<-(sample.mesures.h4)
efecte.mesures.h5<-(sample.mesures.h5)
efecte.mesures.h6<-(sample.mesures.h6)
efecte.mesures.h7<-(sample.mesures.h7)
efecte.mesures.h8<-(sample.mesures.h8)
efecte.mesures.h9<-(sample.mesures.h9)
efecte.mesures.h10<-(sample.mesures.h10)
efecte.mesures.h11<-(sample.mesures.h11)
efecte.mesures.h12<-(sample.mesures.h12)
efecte.mesures.h13<-(sample.mesures.h13)
efecte.mesures.h14<-(sample.mesures.h14)
efecte.mesures.h15<-(sample.mesures.h15)
efecte.mesures.h16<-(sample.mesures.h16)
efecte.mesures.h17<-(sample.mesures.h17)
efecte.mesures.h18<-(sample.mesures.h18)
efecte.mesures.h19<-(sample.mesures.h19)
efecte.mesures.h20<-(sample.mesures.h20)
efecte.mesures.h21<-(sample.mesures.h21)
efecte.mesures.h22<-(sample.mesures.h22)
efecte.mesures.h23<-(sample.mesures.h23)

```

```

mitjana<-
c(mean(efecte.mesures.h1),mean(efecte.mesures.h2),mean(efecte.mesures.
h3),mean(efecte.mesures.h4),mean(efecte.mesures.h5),mean(efecte.mesure
s.h6),
mean(efecte.mesures.h7),mean(efecte.mesures.h8),mean(efecte.mesures.h9
),mean(efecte.mesures.h10),mean(efecte.mesures.h11),mean(efecte.mesure
s.h12),
mean(efecte.mesures.h13),mean(efecte.mesures.h14),mean(efecte.mesures.
h15),mean(efecte.mesures.h16),mean(efecte.mesures.h17),mean(efecte.mes
ures.h18),
mean(efecte.mesures.h19),mean(efecte.mesures.h20),mean(efecte.mesures.
h21),mean(efecte.mesures.h22),mean(efecte.mesures.h23))

```

```

ic.inf<-
c(quantile(efecte.mesures.h1,0.025),quantile(efecte.mesures.h2,0.025),
quantile(efecte.mesures.h3,0.025),quantile(efecte.mesures.h4,0.025),qu
antile(efecte.mesures.h5,0.025),quantile(efecte.mesures.h6,0.025),
quantile(efecte.mesures.h7,0.025),quantile(efecte.mesures.h8,0.025),qu
antile(efecte.mesures.h9,0.025),quantile(efecte.mesures.h10,0.025),qua
ntile(efecte.mesures.h11,0.025),quantile(efecte.mesures.h12,0.025),
quantile(efecte.mesures.h13,0.025),quantile(efecte.mesures.h14,0.025),
quantile(efecte.mesures.h15,0.025),quantile(efecte.mesures.h16,0.025),
quantile(efecte.mesures.h17,0.025),quantile(efecte.mesures.h18,0.025),

```

```
quantile(efecte.mesures.h19,0.025),quantile(efecte.mesures.h20,0.025),
quantile(efecte.mesures.h21,0.025),quantile(efecte.mesures.h22,0.025),
quantile(efecte.mesures.h23,0.025))
```

```
ic.sup<-
c(quantile(efecte.mesures.h1,0.975),quantile(efecte.mesures.h2,0.975),
quantile(efecte.mesures.h3,0.975),quantile(efecte.mesures.h4,0.975),qu
antile(efecte.mesures.h5,0.975),quantile(efecte.mesures.h6,0.975),
quantile(efecte.mesures.h7,0.975),quantile(efecte.mesures.h8,0.975),qu
antile(efecte.mesures.h9,0.975),quantile(efecte.mesures.h10,0.975),qua
ntile(efecte.mesures.h11,0.975),quantile(efecte.mesures.h12,0.975),
quantile(efecte.mesures.h13,0.975),quantile(efecte.mesures.h14,0.975),
quantile(efecte.mesures.h15,0.975),quantile(efecte.mesures.h16,0.975),
quantile(efecte.mesures.h17,0.975),quantile(efecte.mesures.h18,0.975),
quantile(efecte.mesures.h19,0.975),quantile(efecte.mesures.h20,0.975),
quantile(efecte.mesures.h21,0.975),quantile(efecte.mesures.h22,0.975),
quantile(efecte.mesures.h23,0.975))
```

```
par(oma=c(2,1,2,1))
plot(1:23,mitjana,ylim=c(min(ic.inf),max(ic.sup)),xlim=c(0.95,23.05),p
ch=19,main="Coeficients associats a la infecció dels
hospitals",xlab="Hospitals",ylab="",col="darkgreen")
points(1:23,ic.inf,pch=95,col="darkgreen")
points(1:23,ic.sup,pch=95,col="darkgreen")
axis(1,seq(1:23))
abline(h=0,col="red")
for (i in 1:23){
  lines(c(i,i),c(ic.inf[i],ic.sup[i]),col="darkgreen")
}
box("outer",lwd=10,col="lightgoldenrod4")
```

```
### COLON. ORGANO-CAVITARIA
```

```
#### MODEL 1: EFECTE VARIABLES PACIENT (Edat, sexe, imc)
```

```
infeccio<-as.numeric(IEQ_OC)-1
temps<-MES_ESTUDI
edat<-Edad
sexe<-as.numeric(Genero)-1 ## 0 = Home/ 1 = Dona
imc<-IMC
hospital<- IdHospital
Datos<-data.frame(hospital=hospital,infeccio, edat=edat, sexe=sexe,
imc=imc)

formula = infeccio~1
formula = infeccio~ f(hospital,model="iid")+1

resultat.1 = inla(formula, family="binomial", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
), data=Datos, verbose=T)
```

```

summary(resultat.1)

resultat.1$dic$dic

-mean(log(resultat.1$cpo),na.rm=T)
-mean(log(resultat.1$cpo[resultat.1$cpo>0]),na.rm=T)

#### MODEL 2: EFECTE VARIABLES RISC DE PACIENT (Charlson, ASA, NNIS,
Glucèmia)
Datos<-data.frame(hospital=hospital, infeccio, edat=edat, sexe=sexe,
imc=imc)
charlson<-as.numeric(AntCharlson_cat)-1 ## 0 = <2/ 1 = >2
asa<-as.numeric(ASA_cat)-1 ## 0 = 1-2/ 1 = 3-4
nnis<-as.numeric(RiesgoIEQ_Cat)-1 ## 0 = -1/0 / 1 = 1/2/3
hemoglobina<-as.numeric(DetHemoglobinaNivel_cat)-1 ## 0 = Menys 10 o
Més 18/ 1 = Entre 10 i 18
Datos<-data.frame(Datos, charlson, asa, nnis, hemoglobina)

formula = infeccio~ asa
formula = infeccio~ f(hospital,model="iid")+asa

resultat.2 = inla(formula, family="binomial", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
), data=Datos,verbose=T)

summary(resultat.2)

resultat.2$dic$dic
-mean(log(resultat.2$cpo),na.rm=T)
-mean(log(resultat.2$cpo[resultat.2$cpo>0]),na.rm=T)

par(mfrow=c(1,2))
plot(resultat.2$marginals.fixed$"asa"[,1],resultat.2$marginals.fixed$"
asa"[,2],xlab="",ylab="",main="Efecte ASA")
abline(v=0,col="red")

#### MODEL 3: EFECTE VARIABLES RISC DE CIRURGIA, PRÀCTICA,... (Tipus
antibiòtic, temps antibiòtic, temperatures, ostomia)

Datos<-data.frame(hospital=hospital,infeccio, edat=edat, sexe=sexe,
imc=imc)
Datos<-data.frame(Datos, charlson, asa, nnis, hemoglobina)
tipo.cirurgia<-as.numeric(TipoCirugia2)-1 ## Oberta
cirurgia<-as.numeric(Cirujano)-1 ## 0 = Staff/ 1 = Resident
Hora.Antibiotic<-as.numeric(TiemopAntibiotico_cat)-1 ## 0 = <1 h / 1 =
>1h
transfusions<-as.numeric(TransfusionPeri)-1 ## 0 = No / 1 = Sí
Datos<-data.frame(Datos, tipo.cirurgia, cirurgia, Hora.Antibiotic,
transfusions)

formula =
infeccio~asa+tipo.cirurgia+cirurgia+Hora.Antibiotic+transfusions
formula = infeccio~
f(hospital,model="iid")+asa+tipo.cirurgia+cirurgia+Hora.Antibiotic+tra
nsfusions

```

```

resultat.3 = inla(formula, family="binomial", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
), data=Datos,verbose=T)

summary(resultat.3)

resultat.3$dic$dic
-mean(log(resultat.3$cpo),na.rm=T)
-mean(log(resultat.3$cpo[resultat.3$cpo>0]),na.rm=T)

### Plot dels efectes fixos del model 2

par(mfrow=c(2,2))
plot(resultat.3$marginals.fixed$"asa"[,1],resultat.3$marginals.fixed$
asa[,2],xlab="",ylab="",main="Efecte ASA")
abline(v=0,col="red")
plot(resultat.3$marginals.fixed$"tipo.cirurgia"[,1],resultat.3$margina
ls.fixed$"tipo.cirurgia"[,2],xlab="",ylab="",main="Efecte Tipus
Cirurgia")
abline(v=0,col="red")
plot(resultat.3$marginals.fixed$"cirurgia"[,1],resultat.3$marginals.fi
xed$"cirurgia"[,2],xlab="",ylab="",main="Cirurgia")
abline(v=0,col="red")
plot(resultat.3$marginals.fixed$"transfusions"[,1],resultat.3$marginal
s.fixed$"transfusions"[,2],xlab="",ylab="",main="Transfusions")
abline(v=0,col="red")

#### MODEL 4: EFECTE MESURES

Datos<-data.frame(hospital=hospital, infeccio, edat=edat, sexe=sexe,
imc=imc)
Datos<-data.frame(Datos, charlson, asa, nnis, hemoglobina)
Datos<-data.frame(Datos, tipo.cirurgia, cirurgia, Hora.Antibiotic,
transfusions)

explicativa<-as.numeric(AcomplimentMesuresTotesOC)-1
temps<-MES_ESTUDI
Datos<-data.frame(Datos, explicativa,temps)

formula = infeccio~
asa+tipo.cirurgia+cirurgia+Hora.Antibiotic+transfusions+explicativa+te
mps
formula = infeccio~
f(hospital,model="iid")+asa+tipo.cirurgia+cirurgia+Hora.Antibiotic+tra
nsfusions+explicativa+temps

resultat.4 = inla(formula, family="binomial", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
), data=Datos,verbose=T)

summary(resultat.4)

resultat.4$dic$dic
-mean(log(resultat.4$cpo),na.rm=T)
-mean(log(resultat.4$cpo[resultat.4$cpo>0]),na.rm=T)

```

```

par(mfrow=c(2,4))
plot(resultat.4$marginals.fixed$"asa"[,1],resultat.4$marginals.fixed$
asa[,2],xlab="",ylab="",main="Efecte ASA (III-
IV)",col="darkred",pch=19)
abline(v=0,col="red")
plot(resultat.4$marginals.fixed$"tipo.cirurgia"[,1],resultat.4$margina
ls.fixed$"tipo.cirurgia"[,2],xlab="",ylab="",main="Efecte Tipus
Cirurgia (No Oberta)",col="darkgreen",pch=19)
abline(v=0,col="red")
plot(resultat.4$marginals.fixed$"cirurgia"[,1],resultat.4$marginals.fi
xed$"cirurgia"[,2],xlab="",ylab="",main="Efecte Cirurgia
(Resident)",col="darkred",pch=19)
abline(v=0,col="red")
plot(resultat.4$marginals.fixed$"Hora.Antibiotic"[,1],resultat.4$margi
nals.fixed$"Hora.Antibiotic"[,2],xlab="",ylab="",main="Efecte Hora
Administració (>1 hora)",col="darkgreen",pch=19)
abline(v=0,col="red")
plot(resultat.4$marginals.fixed$"transfusions"[,1],resultat.4$marginal
s.fixed$"transfusions"[,2],xlab="",ylab="",main="Efecte Transfusions
(Sí)",col="darkred",pch=19)
abline(v=0,col="red")
plot(resultat.4$marginals.fixed$"explicativa"[,1],resultat.4$marginals
.fixed$"explicativa"[,2],xlab="",ylab="",main="Mesures
(Acompliment)",col="darkgreen",pch=19)
abline(v=0,col="red")
plot(resultat.4$marginals.fixed$"temps"[,1],resultat.4$marginals.fixed
$"temps"[,2],xlab="",ylab="",main="Efecte Mes",col="darkgreen",pch=19)
abline(v=0,col="red")
box("outer",lwd=10,col="lightgoldenrod4")

```

```
## Efecte aleatori
```

```
# Generem una mostra aleatoria de l'efecte aleatori de les mesures per
cada hospital
```

```

sample.mesures.h1 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[1]][[1]])
sample.mesures.h2 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[2]][[1]])
sample.mesures.h3 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[3]][[1]])
sample.mesures.h4 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[4]][[1]])
sample.mesures.h5 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[5]][[1]])
sample.mesures.h6 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[6]][[1]])
sample.mesures.h7 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[7]][[1]])
sample.mesures.h8 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[8]][[1]])

```



```

sample.mesures.h9 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[9]][[1]])
sample.mesures.h10 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[10]][[1]])
sample.mesures.h11 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[11]][[1]])
sample.mesures.h12 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[12]][[1]])
sample.mesures.h13 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[13]][[1]])
sample.mesures.h14 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[14]][[1]])
sample.mesures.h15 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[15]][[1]])
sample.mesures.h16 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[16]][[1]])
sample.mesures.h17 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[17]][[1]])
sample.mesures.h18 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[18]][[1]])
sample.mesures.h19 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[19]][[1]])
sample.mesures.h20 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[20]][[1]])
sample.mesures.h21 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[21]][[1]])
sample.mesures.h22 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[22]][[1]])
sample.mesures.h23 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[23]][[1]])

```

## Efecte de les caigudes per cada hospital

```

efecte.mesures.h1<-(sample.mesures.h1)
efecte.mesures.h2<-(sample.mesures.h2)
efecte.mesures.h3<-(sample.mesures.h3)
efecte.mesures.h4<-(sample.mesures.h4)
efecte.mesures.h5<-(sample.mesures.h5)
efecte.mesures.h6<-(sample.mesures.h6)
efecte.mesures.h7<-(sample.mesures.h7)
efecte.mesures.h8<-(sample.mesures.h8)
efecte.mesures.h9<-(sample.mesures.h9)
efecte.mesures.h10<-(sample.mesures.h10)
efecte.mesures.h11<-(sample.mesures.h11)
efecte.mesures.h12<-(sample.mesures.h12)
efecte.mesures.h13<-(sample.mesures.h13)

```

```

efecte.mesures.h14<-(sample.mesures.h14)
efecte.mesures.h15<-(sample.mesures.h15)
efecte.mesures.h16<-(sample.mesures.h16)
efecte.mesures.h17<-(sample.mesures.h17)
efecte.mesures.h18<-(sample.mesures.h18)
efecte.mesures.h19<-(sample.mesures.h19)
efecte.mesures.h20<-(sample.mesures.h20)
efecte.mesures.h21<-(sample.mesures.h21)
efecte.mesures.h22<-(sample.mesures.h22)
efecte.mesures.h23<-(sample.mesures.h23)

mitjana<-
c(mean(efecte.mesures.h1),mean(efecte.mesures.h2),mean(efecte.mesures.
h3),mean(efecte.mesures.h4),mean(efecte.mesures.h5),mean(efecte.mesure
s.h6),
mean(efecte.mesures.h7),mean(efecte.mesures.h8),mean(efecte.mesures.h9
),mean(efecte.mesures.h10),mean(efecte.mesures.h11),mean(efecte.mesure
s.h12),
mean(efecte.mesures.h13),mean(efecte.mesures.h14),mean(efecte.mesures.
h15),mean(efecte.mesures.h16),mean(efecte.mesures.h17),mean(efecte.mes
ures.h18),
mean(efecte.mesures.h19),mean(efecte.mesures.h20),mean(efecte.mesures.
h21),mean(efecte.mesures.h22),mean(efecte.mesures.h23))

ic.inf<-
c(quantile(efecte.mesures.h1,0.025),quantile(efecte.mesures.h2,0.025),
quantile(efecte.mesures.h3,0.025),quantile(efecte.mesures.h4,0.025),qu
antile(efecte.mesures.h5,0.025),quantile(efecte.mesures.h6,0.025),
quantile(efecte.mesures.h7,0.025),quantile(efecte.mesures.h8,0.025),qu
antile(efecte.mesures.h9,0.025),quantile(efecte.mesures.h10,0.025),qua
ntile(efecte.mesures.h11,0.025),quantile(efecte.mesures.h12,0.025),
quantile(efecte.mesures.h13,0.025),quantile(efecte.mesures.h14,0.025),
quantile(efecte.mesures.h15,0.025),quantile(efecte.mesures.h16,0.025),
quantile(efecte.mesures.h17,0.025),quantile(efecte.mesures.h18,0.025),
quantile(efecte.mesures.h19,0.025),quantile(efecte.mesures.h20,0.025),
quantile(efecte.mesures.h21,0.025),quantile(efecte.mesures.h22,0.025),
quantile(efecte.mesures.h23,0.025))

ic.sup<-
c(quantile(efecte.mesures.h1,0.975),quantile(efecte.mesures.h2,0.975),
quantile(efecte.mesures.h3,0.975),quantile(efecte.mesures.h4,0.975),qu
antile(efecte.mesures.h5,0.975),quantile(efecte.mesures.h6,0.975),
quantile(efecte.mesures.h7,0.975),quantile(efecte.mesures.h8,0.975),qu
antile(efecte.mesures.h9,0.975),quantile(efecte.mesures.h10,0.975),qua
ntile(efecte.mesures.h11,0.975),quantile(efecte.mesures.h12,0.975),
quantile(efecte.mesures.h13,0.975),quantile(efecte.mesures.h14,0.975),
quantile(efecte.mesures.h15,0.975),quantile(efecte.mesures.h16,0.975),
quantile(efecte.mesures.h17,0.975),quantile(efecte.mesures.h18,0.975),
quantile(efecte.mesures.h19,0.975),quantile(efecte.mesures.h20,0.975),
quantile(efecte.mesures.h21,0.975),quantile(efecte.mesures.h22,0.975),
quantile(efecte.mesures.h23,0.975))

par(oma=c(2,1,2,1))
plot(1:23,mitjana,ylim=c(min(ic.inf),max(ic.sup)),xlim=c(0.95,23.05),p
ch=19,main="Coeficients associats a la infecció dels
hospitals",xlab="Hospitals",ylab="",col="darkgreen")
points(1:23,ic.inf,pch=95,col="darkgreen")
points(1:23,ic.sup,pch=95,col="darkgreen")

```

```

axis(1,seq(1:23))
abline(h=0,col="red")
for (i in 1:23){
  lines(c(i,i),c(ic.inf[i],ic.sup[i]),col="darkgreen")
}
box("outer",lwd=10,col="lightgoldenrod4")

## RECTE. INCISIONAL.

#### MODEL 1: EFECTE VARIABLES PACIENT (Edat, sexe, imc)

infeccio<-as.numeric(IEQ_I)-1
hospital<-IdHospital
temps<-MES_ESTUDI
edat<-Edad
sexe<-as.numeric(Genero)-1 ## 0 = Home/ 1 = Dona
imc<-IMC
hipertensio<-as.numeric(AntHipertension) ## 0 = No/ 1= Sí
cardiopatia<-as.numeric(AntCardiopatia)-1 ## 0 = No/ 1 = Sí
charlson<-as.numeric(AntCharlson_cat)-1 ## 0 = <2/ 1 = >2
glucemia48 <- Glucemia48_BONA
anastomosis<- as.numeric(Anastomosis)-1 ## 0 = No/ 1 = Sí
ostomia<-as.numeric(Ostomia)-1 ## 0 = No/ 1 = Sí
nnis<-as.numeric(RiesgoIEQ_Cat)-1 ## 0 = -1/0 / 1 = 1/2/3

explicativa<-as.numeric(AcomplimentMesuresTotes_2)-1
Datos<-data.frame(hospital, infeccio, edat, sexe, imc,hipertensio,
cardiopatia, charlson, glucemia48, anastomosis, ostomia, nnis,
explicativa,
temps)

formula = infeccio~
edat+nnis+hipertensio+charlson+anastomosis+explicativa*temps
formula = infeccio~
f(hospital,model="iid")+edat+nnis+hipertensio+charlson+anastomosis+exp
licativa*temps

resultat.1 = inla(formula, family="binomial", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
), data=Datos,verbose=T)

summary(resultat.1)

resultat.1$dic$dic
-mean(log(resultat.1$cpo),na.rm=T)
-mean(log(resultat.1$cpo[resultat.1$cpo>0]),na.rm=T)

par(mfrow=c(2,4))
plot(resultat.1$marginals.fixed$"edat"[,1],resultat.1$marginals.fixed$
"edat"[,2],xlab="",ylab="",main="Efecte Edat",col="darkgreen",pch=19)
abline(v=0,col="red")
plot(resultat.1$marginals.fixed$"nnis"[,1],resultat.1$marginals.fixed$
"nnis"[,2],xlab="",ylab="",main="Efecte NNIS
(1/2/3)",col="darkred",pch=19)
abline(v=0,col="red")

```

```

plot(resultat.1$marginals.fixed$"hipertensio"[,1],resultat.1$marginals
.fixed$"hipertensio"[,2],xlab="",ylab="",main="Efecte Hipertensió
(Sí)",col="darkred",pch=19)
abline(v=0,col="red")
plot(resultat.1$marginals.fixed$"charlson"[,1],resultat.1$marginals.fi
xed$"charlson"[,2],xlab="",ylab="",main="Efecte Charlson
(>2)",col="darkred",pch=19)
abline(v=0,col="red")
plot(resultat.1$marginals.fixed$"anastomosis"[,1],resultat.1$marginals
.fixed$"anastomosis"[,2],xlab="",ylab="",main="Efecte Anastomosis
(Sí)",col="darkred",pch=19)
abline(v=0,col="red")
plot(resultat.1$marginals.fixed$"explicativa"[,1],resultat.1$marginals
.fixed$"explicativa"[,2],xlab="",ylab="",main="Efecte Mesures
(Acompliment)",col="darkgreen",pch=19)
abline(v=0,col="red")
plot(resultat.1$marginals.fixed$"temps"[,1],resultat.1$marginals.fixed
$"temps"[,2],xlab="",ylab="",main="Efecte Mes",col="darkgreen",pch=19)
abline(v=0,col="red")
plot(resultat.1$marginals.fixed$"explicativa:temps"[,1],resultat.1$mar
ginals.fixed$"explicativa:temps"[,2],xlab="",ylab="",main="Efecte
Mesures:Temps",col="darkred",pch=19)
abline(v=0,col="red")
box("outer",lwd=10,col="lightgoldenrod4")

```

```
## Efecte aleatori
```

```
# Generem una mostra aleatoria de l'efecte aleatori de les mesures per
cada hospital
```

```
resultat.4<-resultat.1
```

```

sample.mesures.h1 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[1]][[1]])
sample.mesures.h2 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[2]][[1]])
sample.mesures.h3 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[3]][[1]])
sample.mesures.h4 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[4]][[1]])
sample.mesures.h5 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[5]][[1]])
sample.mesures.h6 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[6]][[1]])
sample.mesures.h7 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[7]][[1]])
sample.mesures.h8 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[8]][[1]])
sample.mesures.h9 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[9]][[1]])

```

```

sample.mesures.h10 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[10]][[1]])
sample.mesures.h11 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[11]][[1]])
sample.mesures.h12 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[12]][[1]])
sample.mesures.h13 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[13]][[1]])
sample.mesures.h14 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[14]][[1]])
sample.mesures.h15 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[15]][[1]])
sample.mesures.h16 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[16]][[1]])
sample.mesures.h17 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[17]][[1]])
sample.mesures.h18 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[18]][[1]])
sample.mesures.h19 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[19]][[1]])
sample.mesures.h20 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[20]][[1]])
sample.mesures.h21 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[21]][[1]])
sample.mesures.h22 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[22]][[1]])
sample.mesures.h23 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[23]][[1]])

```

## Efecte de les caigudes per cada hospital

```

efecte.mesures.h1<-(sample.mesures.h1)
efecte.mesures.h2<-(sample.mesures.h2)
efecte.mesures.h3<-(sample.mesures.h3)
efecte.mesures.h4<-(sample.mesures.h4)
efecte.mesures.h5<-(sample.mesures.h5)
efecte.mesures.h6<-(sample.mesures.h6)
efecte.mesures.h7<-(sample.mesures.h7)
efecte.mesures.h8<-(sample.mesures.h8)
efecte.mesures.h9<-(sample.mesures.h9)
efecte.mesures.h10<-(sample.mesures.h10)
efecte.mesures.h11<-(sample.mesures.h11)
efecte.mesures.h12<-(sample.mesures.h12)
efecte.mesures.h13<-(sample.mesures.h13)
efecte.mesures.h14<-(sample.mesures.h14)
efecte.mesures.h15<-(sample.mesures.h15)
efecte.mesures.h16<-(sample.mesures.h16)

```

```

efecte.mesures.h17<-(sample.mesures.h17)
efecte.mesures.h18<-(sample.mesures.h18)
efecte.mesures.h19<-(sample.mesures.h19)
efecte.mesures.h20<-(sample.mesures.h20)
efecte.mesures.h21<-(sample.mesures.h21)
efecte.mesures.h22<-(sample.mesures.h22)
efecte.mesures.h23<-(sample.mesures.h23)

mitjana<-
c(mean(efecte.mesures.h1),mean(efecte.mesures.h2),mean(efecte.mesures.
h3),mean(efecte.mesures.h4),mean(efecte.mesures.h5),mean(efecte.mesure
s.h6),
mean(efecte.mesures.h7),mean(efecte.mesures.h8),mean(efecte.mesures.h9
),mean(efecte.mesures.h10),mean(efecte.mesures.h11),mean(efecte.mesure
s.h12),
mean(efecte.mesures.h13),mean(efecte.mesures.h14),mean(efecte.mesures.
h15),mean(efecte.mesures.h16),mean(efecte.mesures.h17),mean(efecte.mes
ures.h18),
mean(efecte.mesures.h19),mean(efecte.mesures.h20),mean(efecte.mesures.
h21),mean(efecte.mesures.h22),mean(efecte.mesures.h23))

ic.inf<-
c(quantile(efecte.mesures.h1,0.025),quantile(efecte.mesures.h2,0.025),
quantile(efecte.mesures.h3,0.025),quantile(efecte.mesures.h4,0.025),qu
antile(efecte.mesures.h5,0.025),quantile(efecte.mesures.h6,0.025),
quantile(efecte.mesures.h7,0.025),quantile(efecte.mesures.h8,0.025),qu
antile(efecte.mesures.h9,0.025),quantile(efecte.mesures.h10,0.025),qua
ntile(efecte.mesures.h11,0.025),quantile(efecte.mesures.h12,0.025),
quantile(efecte.mesures.h13,0.025),quantile(efecte.mesures.h14,0.025),
quantile(efecte.mesures.h15,0.025),quantile(efecte.mesures.h16,0.025),
quantile(efecte.mesures.h17,0.025),quantile(efecte.mesures.h18,0.025),
quantile(efecte.mesures.h19,0.025),quantile(efecte.mesures.h20,0.025),
quantile(efecte.mesures.h21,0.025),quantile(efecte.mesures.h22,0.025),
quantile(efecte.mesures.h23,0.025))

ic.sup<-
c(quantile(efecte.mesures.h1,0.975),quantile(efecte.mesures.h2,0.975),
quantile(efecte.mesures.h3,0.975),quantile(efecte.mesures.h4,0.975),qu
antile(efecte.mesures.h5,0.975),quantile(efecte.mesures.h6,0.975),
quantile(efecte.mesures.h7,0.975),quantile(efecte.mesures.h8,0.975),qu
antile(efecte.mesures.h9,0.975),quantile(efecte.mesures.h10,0.975),qua
ntile(efecte.mesures.h11,0.975),quantile(efecte.mesures.h12,0.975),
quantile(efecte.mesures.h13,0.975),quantile(efecte.mesures.h14,0.975),
quantile(efecte.mesures.h15,0.975),quantile(efecte.mesures.h16,0.975),
quantile(efecte.mesures.h17,0.975),quantile(efecte.mesures.h18,0.975),
quantile(efecte.mesures.h19,0.975),quantile(efecte.mesures.h20,0.975),
quantile(efecte.mesures.h21,0.975),quantile(efecte.mesures.h22,0.975),
quantile(efecte.mesures.h23,0.975))

par(oma=c(2,1,2,1))
plot(1:23,mitjana,ylim=c(min(ic.inf),max(ic.sup)),xlim=c(0.95,23.05),p
ch=19,main="Coeficients associats a la infecció dels
hospitals",xlab="Hospitals",ylab="",col="darkgreen")
points(1:23,ic.inf,pch=95,col="darkgreen")
points(1:23,ic.sup,pch=95,col="darkgreen")
axis(1,seq(1:23))
abline(h=0,col="red")
for (i in 1:23){

```

```

        lines(c(i,i),c(ic.inf[i],ic.sup[i]),col="darkgreen")
    }
    box("outer",lwd=10,col="lightgoldenrod4")

## RECTE. OC.

#### MODEL 1:

infeccio<-as.numeric(IEQ_OC)-1
hospital<-IdHospital
temps<-MES_ESTUDI
explicativa<-as.numeric(AcomplimentMesuresTotes_2)-1
Datos<-data.frame(hospital, infeccio, explicativa,temps)

formula = infeccio~ explicativa*temps
formula = infeccio~ f(hospital,model="iid")

resultat.1 = inla(formula, family="binomial", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
), data=Datos,verbose=T)

summary(resultat.1)

resultat.1$dic$dic
-mean(log(resultat.1$cpo),na.rm=T)
-mean(log(resultat.1$cpo[resultat.1$cpo>0]),na.rm=T)

par(mfrow=c(1,3),oma=c(8,2,8,2))
plot(resultat.1$marginals.fixed$"explicativa"[,1],resultat.1$marginals
.fixed$"explicativa"[,2],xlab="",ylab="",main="Efecte Mesures
(Acompliment)",col="black",pch=19)
abline(v=0,col="red")
plot(resultat.1$marginals.fixed$"temps"[,1],resultat.1$marginals.fixed
$"temps"[,2],xlab="",ylab="",main="Efecte Mes",col="black",pch=19)
abline(v=0,col="red")
plot(resultat.1$marginals.fixed$"explicativa:temps"[,1],resultat.1$mar
ginals.fixed$"explicativa:temps"[,2],xlab="",ylab="",main="Efecte
Mesures:Temps",col="black",pch=19)
abline(v=0,col="red")
box("outer",lwd=10,col="lightgoldenrod4")

## Efecte aleatori

# Generem una mostra aleatoria de l'efecte aleatori de les mesures per
cada hospital

resultat.4<-resultat.1

sample.mesures.h1 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[1]][[1]])
sample.mesures.h2 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[2]][[1]])

```

```

sample.mesures.h3 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[3]][[1]])
sample.mesures.h4 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[4]][[1]])
sample.mesures.h5 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[5]][[1]])
sample.mesures.h6 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[6]][[1]])
sample.mesures.h7 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[7]][[1]])
sample.mesures.h8 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[8]][[1]])
sample.mesures.h9 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[9]][[1]])
sample.mesures.h10 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[10]][[1]])
sample.mesures.h11 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[11]][[1]])
sample.mesures.h12 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[12]][[1]])
sample.mesures.h13 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[13]][[1]])
sample.mesures.h14 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[14]][[1]])
sample.mesures.h15 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[15]][[1]])
sample.mesures.h16 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[16]][[1]])
sample.mesures.h17 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[17]][[1]])
sample.mesures.h18 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[18]][[1]])
sample.mesures.h19 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[19]][[1]])
sample.mesures.h20 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[20]][[1]])
sample.mesures.h21 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[21]][[1]])
sample.mesures.h22 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[22]][[1]])

```



```
sample.mesures.h23 =
inla.rmarginal(1000,resultat.4$marginals.random$hospital[names(resulta
t.4$marginals.random$hospital)[23]][[1]])
```

```
## Efecte de les caigudes per cada hospital
```

```
efecte.mesures.h1<-(sample.mesures.h1)
efecte.mesures.h2<-(sample.mesures.h2)
efecte.mesures.h3<-(sample.mesures.h3)
efecte.mesures.h4<-(sample.mesures.h4)
efecte.mesures.h5<-(sample.mesures.h5)
efecte.mesures.h6<-(sample.mesures.h6)
efecte.mesures.h7<-(sample.mesures.h7)
efecte.mesures.h8<-(sample.mesures.h8)
efecte.mesures.h9<-(sample.mesures.h9)
efecte.mesures.h10<-(sample.mesures.h10)
efecte.mesures.h11<-(sample.mesures.h11)
efecte.mesures.h12<-(sample.mesures.h12)
efecte.mesures.h13<-(sample.mesures.h13)
efecte.mesures.h14<-(sample.mesures.h14)
efecte.mesures.h15<-(sample.mesures.h15)
efecte.mesures.h16<-(sample.mesures.h16)
efecte.mesures.h17<-(sample.mesures.h17)
efecte.mesures.h18<-(sample.mesures.h18)
efecte.mesures.h19<-(sample.mesures.h19)
efecte.mesures.h20<-(sample.mesures.h20)
efecte.mesures.h21<-(sample.mesures.h21)
efecte.mesures.h22<-(sample.mesures.h22)
efecte.mesures.h23<-(sample.mesures.h23)
```

```
mitjana<-
c(mean(efecte.mesures.h1),mean(efecte.mesures.h2),mean(efecte.mesures.
h3),mean(efecte.mesures.h4),mean(efecte.mesures.h5),mean(efecte.mesure
s.h6),
mean(efecte.mesures.h7),mean(efecte.mesures.h8),mean(efecte.mesures.h9
),mean(efecte.mesures.h10),mean(efecte.mesures.h11),mean(efecte.mesure
s.h12),
mean(efecte.mesures.h13),mean(efecte.mesures.h14),mean(efecte.mesures.
h15),mean(efecte.mesures.h16),mean(efecte.mesures.h17),mean(efecte.mes
ures.h18),
mean(efecte.mesures.h19),mean(efecte.mesures.h20),mean(efecte.mesures.
h21),mean(efecte.mesures.h22),mean(efecte.mesures.h23))
```

```
ic.inf<-
c(quantile(efecte.mesures.h1,0.025),quantile(efecte.mesures.h2,0.025),
quantile(efecte.mesures.h3,0.025),quantile(efecte.mesures.h4,0.025),qu
antile(efecte.mesures.h5,0.025),quantile(efecte.mesures.h6,0.025),
quantile(efecte.mesures.h7,0.025),quantile(efecte.mesures.h8,0.025),qu
antile(efecte.mesures.h9,0.025),quantile(efecte.mesures.h10,0.025),qua
ntile(efecte.mesures.h11,0.025),quantile(efecte.mesures.h12,0.025),
quantile(efecte.mesures.h13,0.025),quantile(efecte.mesures.h14,0.025),
quantile(efecte.mesures.h15,0.025),quantile(efecte.mesures.h16,0.025),
quantile(efecte.mesures.h17,0.025),quantile(efecte.mesures.h18,0.025),
quantile(efecte.mesures.h19,0.025),quantile(efecte.mesures.h20,0.025),
quantile(efecte.mesures.h21,0.025),quantile(efecte.mesures.h22,0.025),
quantile(efecte.mesures.h23,0.025))
```

```
ic.sup<-
c(quantile(efecte.mesures.h1,0.975),quantile(efecte.mesures.h2,0.975),
```

```

quantile(efecte.mesures.h3,0.975),quantile(efecte.mesures.h4,0.975),qu
antile(efecte.mesures.h5,0.975),quantile(efecte.mesures.h6,0.975),
quantile(efecte.mesures.h7,0.975),quantile(efecte.mesures.h8,0.975),qu
antile(efecte.mesures.h9,0.975),quantile(efecte.mesures.h10,0.975),qua
ntile(efecte.mesures.h11,0.975),quantile(efecte.mesures.h12,0.975),
quantile(efecte.mesures.h13,0.975),quantile(efecte.mesures.h14,0.975),
quantile(efecte.mesures.h15,0.975),quantile(efecte.mesures.h16,0.975),
quantile(efecte.mesures.h17,0.975),quantile(efecte.mesures.h18,0.975),
quantile(efecte.mesures.h19,0.975),quantile(efecte.mesures.h20,0.975),
quantile(efecte.mesures.h21,0.975),quantile(efecte.mesures.h22,0.975),
quantile(efecte.mesures.h23,0.975))

```

```

par(oma=c(2,1,2,1))
plot(1:23,mitjana,ylim=c(min(ic.inf),max(ic.sup)),xlim=c(0.95,23.05),p
ch=19,main="Coeficients associats a la infecció dels
hospitals",xlab="Hospitals",ylab="",col="darkgreen")
points(1:23,ic.inf,pch=95,col="darkgreen")
points(1:23,ic.sup,pch=95,col="darkgreen")
axis(1,seq(1:23))
abline(h=0,col="red")
for (i in 1:23){
  lines(c(i,i),c(ic.inf[i],ic.sup[i]),col="darkgreen")
}
box("outer",lwd=10,col="lightgoldenrod4")

```

## **CAIGUDES**

```

### Descriptiva

```

```

#####
suma<-function(x) return(sum(x,na.rm=T))####
media<-function(x) return(mean(x,na.rm=T))####

```

```

#####

```

```

id<-paste(IdHospital,"-",Tabla)
id_u<-paste(IdHospital,"-",Tabla,"-",Unidad)

```

```

#####id<-paste(IdHospital,"-",Unidad)

```

```

## Taxa de caigudes Transversal

```

```

# Agregat per hospital
caigudes_hospi<-
aggregate(datos[,c("NumCaidas_sum","NumPacientes_sum")],by=list(Hospit
al=id),FUN=suma)
# Agregat per unitat
caigudes_unitat<-
aggregate(datos[,c("NumCaidas_sum","NumPacientes_sum")],by=list(Hospit
al=Unidad),FUN=suma)
# Agregat per hospital i unitat

```

```

caigudes_hospi_unitat<-
aggregate(datos[,c("NumCaidas_sum", "NumPacientes_sum")],by=list(Hospital=id_u),FUN=suma)

par(mfrow=c(1,3),cex.main=2,cex.axis=1.5,cex.lab=1.5,oma=c(6,1,6,1))
stripchart((caigudes_hospi$NumCaidas_sum/caigudes_hospi$NumPacientes_sum)*1000,method="jitter",ylab="Taxa de caigudes",vertical=T,pch=16,main=paste("Distribució de la taxa de caigudes",sep="\n", "en els centres participants"),col="darkred",cex=1.8,ylim=c(0,40))
boxplot((caigudes_hospi$NumCaidas_sum/caigudes_hospi$NumPacientes_sum)*1000,outline=F,add=T)
stripchart((caigudes_unitat$NumCaidas_sum/caigudes_unitat$NumPacientes_sum)*1000,method="jitter",ylab="Taxa de caigudes",vertical=T,pch=16,main=paste("Distribució de la taxa de caigudes",sep="\n", "en les unitats participants"),col="darkorange",cex=1.8)
boxplot((caigudes_unitat$NumCaidas_sum/caigudes_unitat$NumPacientes_sum)*1000,outline=F,add=T)
stripchart((caigudes_hospi_unitat$NumCaidas_sum/caigudes_hospi_unitat$NumPacientes_sum)*1000,method="jitter",ylab="Taxa de caigudes",vertical=T,pch=16,main=paste("Distribució de la taxa de caigudes",sep="\n", "en les unitats dels centres participants"),col="olivedrab2",cex=1.8,ylim=c(0,40))
boxplot((caigudes_hospi_unitat$NumCaidas_sum/caigudes_hospi_unitat$NumPacientes_sum)*1000,outline=F,add=T)
box("outer",lwd=10,col="lightgoldenrod4")

summary((caigudes_hospi$NumCaidas_sum/caigudes_hospi$NumPacientes_sum)*1000)
summary((caigudes_unitat$NumCaidas_sum/caigudes_unitat$NumPacientes_sum)*1000)
summary((caigudes_hospi_unitat$NumCaidas_sum/caigudes_hospi_unitat$NumPacientes_sum)*1000)

## Evolució

#caigudes_hospi_mes<-
aggregate(datos[,c("NumCaidas_sum", "NumPacientes_sum")],by=list(Hospital=id,Temps=Quinzena),FUN=suma)
#taxa_hospi_mes<-
(caigudes_hospi_mes$NumCaidas_sum[which(caigudes_hospi_mes$NumPacientes_sum>0)]/caigudes_hospi_mes$NumPacientes_sum[which(caigudes_hospi_mes$NumPacientes_sum>0)])*1000
#mesures_hospi_mes<-
aggregate(datos[, "Percent_mean"],by=list(Hospital=id,Temps=Quinzena),FUN=media)

#m.caigudes<-rep(NA,12)
#m.mesures<-rep(NA,12)
#for(i in 1:12){
#  m.caigudes[i]<-
media(taxa_hospi_mes[which(caigudes_hospi_mes$Temp== (i-1))])
#  m.mesures[i]<-
media(mesures_hospi_mes[which(mesures_hospi_mes$Temp== (i-1))], "x")*100
#}

```

```

#par(mfrow=c(1,2),oma=c(0,2,2,1))
#plot(1:12,m.caigudes,axes=F,xlab="Quinzena",ylab="Taxa
caigudes",main=paste("Evolució de la Taxa de Caigudes",sep="\n","en
els centres participants"),pch=16,ylim=c(1,max(m.caigudes)+1))
#lines(1:12,m.caigudes,lty=3,col="darkred",lwd=4)
#points(1:12,m.caigudes,pch=19,col="darkred")
#axis(1,1:12)
#axis(2,seq(1,max(m.caigudes)+1,.5))
#box("outer",lwd=10,col="lightgoldenrod4")

#plot(1:12,m.mesures,axes=F,xlab="Quinzena",ylab="Proporció de
mesures",main=paste("Evolució de la proporció de mesures
realitzades",sep="\n","en els centres
participants"),pch=16,ylim=c(min(m.mesures)-1,max(m.mesures)+1))
#lines(1:12,m.mesures,lty=3,col="orange",lwd=4)
#points(1:12,m.mesures,pch=19,col="orange")
#axis(1,1:12)
#axis(2,seq(65,78,2))
#box("outer",lwd=10,col="lightgoldenrod4")

#caigudes_unitat_mes<-
aggregate(datos[,c("NumCaidas_sum","NumPacientes_sum")],by=list(Hospit
al=Unidad,Temps=Quinzena),FUN=suma)
#taxa_unitat_mes<-
(caigudes_unitat_mes$NumCaidas_sum[which(caigudes_unitat_mes$NumPacien
tes_sum>0)]/caigudes_unitat_mes$NumPacientes_sum[which(caigudes_unitat
_mes$NumPacientes_sum>0)])*1000
#mesures_unitat_mes<-
aggregate(datos[, "Percent_mean"],by=list(Hospital=Unidad,Temps=Quinzen
a),FUN=media)

#m.caigudes<-rep(NA,12)
#m.mesures<-rep(NA,12)
#for(i in 1:12){
#   m.caigudes[i]<-
media(taxa_unitat_mes[which(caigudes_unitat_mes$Temps==(i-1)])
#   m.mesures[i]<-
media(mesures_unitat_mes[which(mesures_unitat_mes$Temps==(i-
1)),"x"]*100)
#}

#par(mfrow=c(1,2),oma=c(0,2,2,1))
#plot(1:12,m.caigudes,axes=F,xlab="Quinzena",ylab="Taxa
caigudes",main=paste("Evolució de la Taxa de Caigudes",sep="\n","en
les unitats participants"),pch=16,ylim=c(1,max(m.caigudes)+1))
#lines(1:12,m.caigudes,lty=3,col="darkred",lwd=4)
#points(1:12,m.caigudes,pch=19,col="darkred")
#axis(1,1:12)
#axis(2,seq(1,max(m.caigudes)+1,.5))
#box("outer",lwd=10,col="lightgoldenrod4")

#plot(1:12,m.mesures,axes=F,xlab="Quinzena",ylab="Proporció de
mesures",main=paste("Evolució de la proporció de mesures

```

```

realitzades",sep="\n","en les unitats
participants"),pch=16,ylim=c(min(m.mesures)-1,max(m.mesures)+1))
#lines(1:12,m.mesures,lty=3,col="orange",lwd=4)
#points(1:12,m.mesures,pch=19,col="orange")
#axis(1,1:12)
#axis(2,seq(65,78,2))
#box("outer",lwd=10,col="lightgoldenrod4")

#caigudes_hospi_unitat_mes<-
aggregate(datos[,c("NumCaidas_sum","NumPacientes_sum")],by=list(Hospit
al=id_u,Temp=Quinzena),FUN=suma)
#taxa_hospi_unitat_mes<-
(caigudes_hospi_unitat_mes$NumCaidas_sum[which(caigudes_hospi_unitat_m
es$NumPacientes_sum>0)]/caigudes_hospi_unitat_mes$NumPacientes_sum[whi
ch(caigudes_hospi_unitat_mes$NumPacientes_sum>0)])*1000
#mesures_hospi_unitat_mes<-
aggregate(datos[, "Percent_mean"],by=list(Hospital=id_u,Temp=Quinzena)
,FUN=media)

#m.caigudes<-rep(NA,12)
#m.mesures<-rep(NA,12)
#for(i in 1:12){
#   m.caigudes[i]<-
media(taxa_hospi_unitat_mes[which(caigudes_hospi_unitat_mes$Temp==(i-
1))])
#   m.mesures[i]<-
media(mesures_hospi_unitat_mes[which(mesures_hospi_unitat_mes$Temp==(
i-1)),"x"]*100)
#}

#par(mfrow=c(1,2),oma=c(0,2,2,1))
#plot(1:12,m.caigudes,axes=F,xlab="Quinzena",ylab="Taxa
caigudes",main=paste("Evolució de la Taxa de Caigudes",sep="\n","en
les unitats dels centres
participants"),pch=16,ylim=c(1,max(m.caigudes)+1))
#lines(1:12,m.caigudes,lty=3,col="darkred",lwd=4)
#points(1:12,m.caigudes,pch=19,col="darkred")
#axis(1,1:12)
#axis(2,seq(1,max(m.caigudes)+1,.5))
#box("outer",lwd=10,col="lightgoldenrod4")

#plot(1:12,m.mesures,axes=F,xlab="Quinzena",ylab="Proporció de
mesures",main=paste("Evolució de la proporció de mesures
realitzades",sep="\n","en les unitats dels centres
participants"),pch=16,ylim=c(min(m.mesures)-1,max(m.mesures)+1))
#lines(1:12,m.mesures,lty=3,col="orange",lwd=4)
#points(1:12,m.mesures,pch=19,col="orange")
#axis(1,1:12)
#axis(2,seq(65,78,2))
#box("outer",lwd=10,col="lightgoldenrod4")

```

```
#####

caigudes_mes<-
aggregate(datos[,c("NumCaidas_sum","NumPacientes_sum")],by=list(Temps=
Quinzena),FUN=suma)
taxa_mes<-
(caigudes_mes$NumCaidas_sum[which(caigudes_mes$NumPacientes_sum>0)]/ca
igudes_mes$NumPacientes_sum[which(caigudes_mes$NumPacientes_sum>0)])*1
000
mesures_mes<-
aggregate(datos[, "Percent_mean"],by=list(Temps=Quinzena),FUN=media)

m.caigudes<-taxa_mes
m.mesures<-mesures_mes$x

par(mfrow=c(1,2),oma=c(5,1,4,0))
plot(1:12,m.caigudes,axes=F,xlab="Quinzena",ylab="Taxa
caigudes",main=paste("Evolució de la Taxa de
Caigudes"),pch=16,ylim=c(1,max(m.caigudes)+1))
lines(1:12,m.caigudes,lty=3,col="darkred",lwd=4)
points(1:12,m.caigudes,pch=19,col="darkred")
axis(1,1:12)
axis(2,seq(1,max(m.caigudes)+1,.5))
box()
box("outer",lwd=10,col="lightgoldenrod4")

plot(1:12,m.mesures,axes=F,xlab="Quinzena",ylab="Proporció de
mesures",main=paste("Evolució de la proporció de mesures
realitzades"),pch=16,ylim=c(0.60,0.80))
lines(1:12,m.mesures,lty=3,col="olivedrab3",lwd=4)
points(1:12,m.mesures,pch=19,col="olivedrab3")
axis(1,1:12)
axis(2,seq(0.60,0.80,.05),seq(60,80,5))
box("outer",lwd=10,col="lightgoldenrod4")
box()

# per unitats

caigudes_mes_1<-
aggregate(datos[which(Unidad==levels(Unidad)[1]),c("NumCaidas_sum","Nu
mPacientes_sum")],by=list(Temps=Quinzena[which(Unidad==levels(Unidad)[
1])]),FUN=suma)
taxa_mes_1<-
(caigudes_mes_1$NumCaidas_sum[which(caigudes_mes_1$NumPacientes_sum>0)
]/caigudes_mes_1$NumPacientes_sum[which(caigudes_mes_1$NumPacientes_su
m>0)])*1000
mesures_mes_1<-
aggregate(datos[which(Unidad==levels(Unidad)[1]), "Percent_mean"],by=li
st(Temps=Quinzena[which(Unidad==levels(Unidad)[1])]),FUN=media)
m.caigudes_1<-taxa_mes_1
m.mesures_1<-mesures_mes_1$x

caigudes_mes_2<-
aggregate(datos[which(Unidad==levels(Unidad)[2]),c("NumCaidas_sum","Nu
mPacientes_sum")],by=list(Temps=Quinzena[which(Unidad==levels(Unidad)[
2])]),FUN=suma)
taxa_mes_2<-
(caigudes_mes_2$NumCaidas_sum[which(caigudes_mes_2$NumPacientes_sum>0)
```

```

]/caigudes_mes_2$NumPacientes_sum[which(caigudes_mes_2$NumPacientes_su
m>0)])*1000
mesures_mes_2<-
aggregate(datos[which(Unidad==levels(Unidad)[2]),"Percent_mean"],by=li
st(Temps=Quinzena[which(Unidad==levels(Unidad)[2])]),FUN=media)
m.caigudes_2<-taxa_mes_2
m.mesures_2<-mesures_mes_2$x

caigudes_mes_3<-
aggregate(datos[which(Unidad==levels(Unidad)[3]),c("NumCaidas_sum","Nu
mPacientes_sum")],by=list(Temps=Quinzena[which(Unidad==levels(Unidad)[
3])]),FUN=suma)
taxa_mes_3<-
(caigudes_mes_2$NumCaidas_sum[which(caigudes_mes_3$NumPacientes_sum>0)
]/caigudes_mes_3$NumPacientes_sum[which(caigudes_mes_3$NumPacientes_su
m>0)])*1000
mesures_mes_3<-
aggregate(datos[which(Unidad==levels(Unidad)[3]),"Percent_mean"],by=li
st(Temps=Quinzena[which(Unidad==levels(Unidad)[3])]),FUN=media)
m.caigudes_3<-taxa_mes_3
m.mesures_3<-mesures_mes_3$x

caigudes_mes_4<-
aggregate(datos[which(Unidad==levels(Unidad)[4]),c("NumCaidas_sum","Nu
mPacientes_sum")],by=list(Temps=Quinzena[which(Unidad==levels(Unidad)[
4])]),FUN=suma)
taxa_mes_4<-
(caigudes_mes_4$NumCaidas_sum[which(caigudes_mes_4$NumPacientes_sum>0)
]/caigudes_mes_4$NumPacientes_sum[which(caigudes_mes_4$NumPacientes_su
m>0)])*1000
mesures_mes_4<-
aggregate(datos[which(Unidad==levels(Unidad)[4]),"Percent_mean"],by=li
st(Temps=Quinzena[which(Unidad==levels(Unidad)[4])]),FUN=media)
m.caigudes_4<-taxa_mes_4
m.mesures_4<-mesures_mes_4$x

caigudes_mes_5<-
aggregate(datos[which(Unidad==levels(Unidad)[5]),c("NumCaidas_sum","Nu
mPacientes_sum")],by=list(Temps=Quinzena[which(Unidad==levels(Unidad)[
5])]),FUN=suma)
taxa_mes_5<-
(caigudes_mes_5$NumCaidas_sum[which(caigudes_mes_5$NumPacientes_sum>0)
]/caigudes_mes_5$NumPacientes_sum[which(caigudes_mes_5$NumPacientes_su
m>0)])*1000
mesures_mes_5<-
aggregate(datos[which(Unidad==levels(Unidad)[5]),"Percent_mean"],by=li
st(Temps=Quinzena[which(Unidad==levels(Unidad)[5])]),FUN=media)
m.caigudes_5<-taxa_mes_5
m.mesures_5<-mesures_mes_5$x

## per tipus de centre

caigudes_mes_css<-
aggregate(datos[which(Tabla==levels(Tabla)[1]),c("NumCaidas_sum","NumP
acientes_sum")],by=list(Temps=Quinzena[which(Tabla==levels(Tabla)[1])])
),FUN=suma)
taxa_mes_css<-
(caigudes_mes_css$NumCaidas_sum[which(caigudes_mes_css$NumPacientes_su
m>0)]/caigudes_mes_css$NumPacientes_sum[which(caigudes_mes_css$NumPaci
entes_sum>0)])*1000

```

```

mesures_mes_css<-
aggregate(datos[which(Tabla==levels(Tabla)[1]),"Percent_mean"],by=list
(Temps=Quinzena[which(Tabla==levels(Tabla)[1])]),FUN=media)
m.caigudes_css<-taxa_mes_css
m.mesures_css<-mesures_mes_css$x

```

```

caigudes_mes_h<-
aggregate(datos[which(Tabla==levels(Tabla)[2]),c("NumCaidas_sum","NumP
acientes_sum")],by=list(Temps=Quinzena[which(Tabla==levels(Tabla)[2])])
),FUN=suma)
taxa_mes_h<-
(caigudes_mes_h$NumCaidas_sum[which(caigudes_mes_h$NumPacientes_sum>0)
]/caigudes_mes_h$NumPacientes_sum[which(caigudes_mes_h$NumPacientes_su
m>0)])*1000
mesures_mes_h<-
aggregate(datos[which(Tabla==levels(Tabla)[2]),"Percent_mean"],by=list
(Temps=Quinzena[which(Tabla==levels(Tabla)[2])]),FUN=media)
m.caigudes_h<-taxa_mes_h
m.mesures_h<-mesures_mes_h$x

```

```

par(mfrow=c(1,2),oma=c(5,1,2,0))
plot(1:12,m.caigudes_css,axes=F,xlab="Quinzena",ylab="Taxa
caigudes",main=paste("Evolució de la Taxa de Caigudes",sep="\n","en
els CSS"),pch=16,ylim=c(0,8))
lines(1:12,m.caigudes_css,lty=1,col="darkred",lwd=4)
points(1:12,m.caigudes_css,pch=19,col="darkred")
lines(1:12,m.caigudes_1,lty=3,col="darkorange",lwd=2)
points(1:12,m.caigudes_1,pch=19,col="darkorange")
lines(1:12,m.caigudes_2,lty=2,col="darkgoldenrod3",lwd=2)
points(1:12,m.caigudes_2,pch=19,col="darkgoldenrod3")
axis(1,1:12)
axis(2,seq(0,7,1))
box()
box("outer",lwd=10,col="lightgoldenrod4")
par(xpd=NA)
legend(0,-2.5,c("Global CSS","Unitat 1","Unitat
2"),col=c("darkred","darkorange","darkgoldenrod3"),lty=c(1,3,2),lwd=2,
bty="n")

```

```

plot(1:12,m.mesures_css,axes=F,xlab="Quinzena",ylab="Proporció de
mesures",main=paste("Evolució de la proporció de mesures
realitzades",sep="\n","en els CSS"),pch=16,ylim=c(0.50,0.90))
lines(1:12,m.mesures_css,lty=1,col="olivedrab3",lwd=4)
points(1:12,m.mesures_css,pch=19,col="olivedrab3")
lines(1:12,m.mesures_1,lty=3,col="aquamarine4",lwd=2)
points(1:12,m.mesures_1,pch=19,col="aquamarine4")
lines(1:12,m.mesures_2,lty=2,col="darkgreen",lwd=2)
points(1:12,m.mesures_2,pch=19,col="darkgreen")
axis(1,1:12)
axis(2,seq(0.50,0.90,.1),seq(50,90,10))
box("outer",lwd=10,col="lightgoldenrod4")
box()
par(xpd=NA)
legend(0,0.38,c("Global CSS","Unitat 1","Unitat
2"),col=c("olivedrab3","aquamarine4","darkgreen"),lty=c(1,3,2),lwd=2,b
ty="n")

```



```

par(mfrow=c(1,2),oma=c(5,1,2,0))
plot(1:12,m.caigudes_h,axes=F,xlab="Quinzena",ylab="Taxa
caigudes",main=paste("Evolució de la Taxa de Caigudes",sep="\n","en
els Hospitals"),pch=16,ylim=c(0,8))
lines(1:12,m.caigudes_h,lty=1,col="darkred",lwd=4)
points(1:12,m.caigudes_h,pch=19,col="darkred")
lines(1:12,m.caigudes_3,lty=2,col="darkorange",lwd=2)
points(1:12,m.caigudes_3,pch=19,col="darkorange")
lines(1:12,m.caigudes_4,lty=3,col="darkgoldenrod3",lwd=2)
points(1:12,m.caigudes_4,pch=19,col="darkgoldenrod3")
lines(1:12,m.caigudes_5,lty=4,col="red",lwd=2)
points(1:12,m.caigudes_5,pch=19,col="red")
axis(1,1:12)
axis(2,seq(0,7,1))
box()
box("outer",lwd=10,col="lightgoldenrod4")
par(xpd=NA)
legend(0,-2,c("Global Hospitals","Unitat SM","Unitat Mèdica","Unitat
Quirúrgica"),col=c("darkred","darkorange","darkgoldenrod3","red"),lty=
c(1,2,3,4),lwd=2,bty="n")

```

```

plot(1:12,m.mesures_h,axes=F,xlab="Quinzena",ylab="Proporció de
mesures",main=paste("Evolució de la proporció de mesures
realitzades",sep="\n","en els Hospitals"),pch=16,ylim=c(0.50,0.90))
lines(1:12,m.mesures_h,lty=1,col="olivedrab3",lwd=4)
points(1:12,m.mesures_h,pch=19,col="olivedrab3")
lines(1:12,m.mesures_3,lty=2,col="aquamarine4",lwd=2)
points(1:12,m.mesures_3,pch=19,col="aquamarine4")
lines(1:12,m.mesures_4,lty=3,col="darkgreen",lwd=2)
points(1:12,m.mesures_4,pch=19,col="darkgreen")
lines(1:12,m.mesures_5,lty=4,col="darkolivegreen",lwd=2)
points(1:12,m.mesures_5,pch=19,col="darkolivegreen")
axis(1,1:12)
axis(2,seq(0.50,0.90,.1),seq(50,90,10))
box("outer",lwd=10,col="lightgoldenrod4")
box()
par(xpd=NA)
legend(0,0.40,c("Global Hospitals","Unitat SM","Unitat Mèdica","Unitat
Quirúrgica"),col=c("olivedrab3","aquamarine4","darkgreen","darkolivegr
een"),lty=c(1,2,3,4),lwd=2,bty="n")

```

```

#source("http://www.math.ntnu.no/inla/givemeINLA.R")

```

```

library(INLA)
inla.upgrade(testing=FALSE)
#setwd("F:/CENTRE DE SEURETAT/Comunidades
autónomas/Catalunya/PROJECTES ASSOCIATS/caigudes/Bases de dades finals
Alex/26-09-2008/Núria/2011 03 28")

```

```

library(foreign)
#contrastar<-
read.spss("Mixtes2.sav",to.data.frame=T,use.value.labels=T)

```

```

datos<-read.spss("Mixtes2.sav",to.data.frame=T,use.value.labels=F)
#attach(datos)

##### MILLORA MESURES PREVENTIVES #####

# Comprovem Normalitat de la variable % de compliment de les mesures.
hist(Percent_mean)
shapiro.test(Percent_mean)
boxplot(Percent_mean) ### Observem dos outliers!!!!

## Dades

explicativa<- Percent_mean
temps<- as.numeric(Quinzena)
hospital<- IdHospital
unidad<-as.factor(as.numeric(Unidad))
tipo<-as.numeric(Tabla)-1

Datos<-data.frame(hospital=hospital,unidad=unidad,
explicativa=explicativa,temps=temps,tipo)

## Model 1: Millora Percentatge de compliment de les mesures
formula = explicativa~temps+tipo
resultat1 = inla(formula, family="gaussian", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE),
data=Datos,verbose=T)

summary(resultat1)

resultat1$dic$dic
-mean(resultat1$cpo,na.rm=T)

## Model 2: Millora Percentatge de compliment de les mesures efectes
fixes hospital
formula = explicativa~temps+tipo+f(hospital,model="iid")
resultat1 = inla(formula, family="gaussian", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE),
data=Datos,verbose=T)

summary(resultat1)

resultat1$dic$dic
-mean(resultat1$cpo,na.rm=T)

plot(resultat1$marginals.fixed$"temps"[,1],resultat1$marginals.fixed$"
temps"[,2],xlab="",ylab="",main="Efecte Temps")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"tipo"[,1],resultat1$marginals.fixed$"t
ipo"[,2],xlab="",ylab="",main="Efecte Hospitales vs CSS")
abline(v=0,col="red")
box("outer",lwd=5)

```

```

efecte.h1 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[1]][[1]])
efecte.h2 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[2]][[1]])
efecte.h3 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[3]][[1]])
efecte.h4 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[4]][[1]])
efecte.h5 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[5]][[1]])
efecte.h6 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[6]][[1]])
efecte.h7 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[7]][[1]])
efecte.h8 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[8]][[1]])
efecte.h9 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[9]][[1]])
efecte.h10 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[10]][[1]])
efecte.h11 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[11]][[1]])
efecte.h12 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[12]][[1]])
efecte.h13 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[13]][[1]])
efecte.h14 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[14]][[1]])
efecte.h15 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[15]][[1]])
efecte.h16 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[16]][[1]])
efecte.h17 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[17]][[1]])
efecte.h18 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[18]][[1]])
efecte.h19 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[19]][[1]])
efecte.h20 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[20]][[1]])

```



```

efecte.h41 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[41]][[1]])
efecte.h42 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[42]][[1]])
efecte.h43 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[43]][[1]])
efecte.h44 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[44]][[1]])

mitjana<-
c(mean(efecte.h1),mean(efecte.h2),mean(efecte.h3),mean(efecte.h4),mean
(efecte.h5),mean(efecte.h6),mean(efecte.h7),mean(efecte.h8),
mean(efecte.h9),mean(efecte.h10),mean(efecte.h11),mean(efecte.h12),mea
n(efecte.h13),mean(efecte.h14),mean(efecte.h15),mean(efecte.h16),
mean(efecte.h17),mean(efecte.h18),mean(efecte.h19),mean(efecte.h20),me
an(efecte.h21),mean(efecte.h22),mean(efecte.h23),mean(efecte.h24),mean
(efecte.h25),
mean(efecte.h26),mean(efecte.h27),mean(efecte.h28),mean(efecte.h29),me
an(efecte.h30),mean(efecte.h31),mean(efecte.h32),mean(efecte.h33),mean
(efecte.h34),
mean(efecte.h35),mean(efecte.h36),mean(efecte.h37),mean(efecte.h38),me
an(efecte.h39),mean(efecte.h40),mean(efecte.h41),mean(efecte.h42),mean
(efecte.h43),
mean(efecte.h44))

ic.inf<-
c(quantile(efecte.h1,0.025),quantile(efecte.h2,0.025),quantile(efecte.
h3,0.025),quantile(efecte.h4,0.025),quantile(efecte.h5,0.025),quantile
(efecte.h6,0.025),quantile(efecte.h7,0.025),quantile(efecte.h8,0.025),
quantile(efecte.h9,0.025),quantile(efecte.h10,0.025),quantile(efecte.h
11,0.025),quantile(efecte.h12,0.025),quantile(efecte.h13,0.025),quanti
le(efecte.h14,0.025),quantile(efecte.h15,0.025),quantile(efecte.h16,0.
025),
quantile(efecte.h17,0.025),quantile(efecte.h18,0.025),quantile(efecte.
h19,0.025),quantile(efecte.h20,0.025),quantile(efecte.h21,0.025),quant
ile(efecte.h22,0.025),quantile(efecte.h23,0.025),quantile(efecte.h24,0
.025),quantile(efecte.h25,0.025),
quantile(efecte.h26,0.025),quantile(efecte.h27,0.025),quantile(efecte.
h28,0.025),quantile(efecte.h29,0.025),quantile(efecte.h30,0.025),quant
ile(efecte.h31,0.025),quantile(efecte.h32,0.025),quantile(efecte.h33,0
.025),quantile(efecte.h34,0.025),
quantile(efecte.h35,0.025),quantile(efecte.h36,0.025),quantile(efecte.
h37,0.025),quantile(efecte.h38,0.025),quantile(efecte.h39,0.025),quant
ile(efecte.h40,0.025),quantile(efecte.h41,0.025),quantile(efecte.h42,0
.025),quantile(efecte.h43,0.025),
quantile(efecte.h44,0.025))

ic.sup<-
c(quantile(efecte.h1,0.975),quantile(efecte.h2,0.975),quantile(efecte.
h3,0.975),quantile(efecte.h4,0.975),quantile(efecte.h5,0.975),quantile
(efecte.h6,0.975),quantile(efecte.h7,0.975),quantile(efecte.h8,0.975),
quantile(efecte.h9,0.975),quantile(efecte.h10,0.975),quantile(efecte.h
11,0.975),quantile(efecte.h12,0.975),quantile(efecte.h13,0.975),quanti
le(efecte.h14,0.975),quantile(efecte.h15,0.975),quantile(efecte.h16,0.
975),

```

```

quantile(efecte.h17,0.975),quantile(efecte.h18,0.975),quantile(efecte.
h19,0.975),quantile(efecte.h20,0.975),quantile(efecte.h21,0.975),quant
ile(efecte.h22,0.975),quantile(efecte.h23,0.975),quantile(efecte.h24,0
.975),quantile(efecte.h25,0.975),
quantile(efecte.h26,0.975),quantile(efecte.h27,0.975),quantile(efecte.
h28,0.975),quantile(efecte.h29,0.975),quantile(efecte.h30,0.975),quant
ile(efecte.h31,0.975),quantile(efecte.h32,0.975),quantile(efecte.h33,0
.975),quantile(efecte.h34,0.975),
quantile(efecte.h35,0.975),quantile(efecte.h36,0.975),quantile(efecte.
h37,0.975),quantile(efecte.h38,0.975),quantile(efecte.h39,0.975),quant
ile(efecte.h40,0.975),quantile(efecte.h41,0.975),quantile(efecte.h42,0
.975),quantile(efecte.h43,0.975),
quantile(efecte.h44,0.975))

```

```

plot(1:44,mitjana,ylim=c(min(ic.inf),max(ic.sup)),col="darkmagenta",xl
im=c(0.95,44.05),pch=19,main="Efecte dels
centres",xlab="Hospitals",ylab="")
abline(h=0,col="darkolivegreen")
points(1:44,ic.inf,pch=95,col="darkmagenta")
points(1:44,ic.sup,pch=95,col="darkmagenta")
#axis(1,seq(1:44),cex.axis=.5)
for (i in 1:44){
  lines(c(i,i),c(ic.inf[i],ic.sup[i]),col="darkmagenta")
}
box("outer",lwd=10,col="lightgoldenrod4")

```

```

## Model 2.BIS: Millora Percentatge de compliment de les mesures
efectes fixes hospital
hospital2<-hospital
Datos<-data.frame(Datos,hospital2)
formula =
explicativa~tipo+f(hospital2,model="iid")+f(hospital,temps,model="iid"
)
resultat1 = inla(formula, family="gaussian", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE),
data=Datos,verbose=T)

summary(resultat1)

```

```

resultat1$dic$dic
-mean(resultat1$cpo,na.rm=T)

```

```

plot(resultat1$marginals.fixed$"temps"[,1],resultat1$marginals.fixed$"
temps"[,2],xlab="",ylab="",main="Efecte Temps")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"tipo"[,1],resultat1$marginals.fixed$"t
ipo"[,2],xlab="",ylab="",main="Efecte Hospitales vs CSS")
abline(v=0,col="red")
box("outer",lwd=5)

```

```

efecte.h1 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[1]][[1]])
efecte.h2 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[2]][[1]])
efecte.h3 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[3]][[1]])
efecte.h4 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[4]][[1]])
efecte.h5 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[5]][[1]])
efecte.h6 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[6]][[1]])
efecte.h7 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[7]][[1]])
efecte.h8 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[8]][[1]])
efecte.h9 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[9]][[1]])
efecte.h10 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[10]][[1]])
efecte.h11 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[11]][[1]])
efecte.h12 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[12]][[1]])
efecte.h13 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[13]][[1]])
efecte.h14 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[14]][[1]])
efecte.h15 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[15]][[1]])
efecte.h16 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[16]][[1]])
efecte.h17 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[17]][[1]])
efecte.h18 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[18]][[1]])
efecte.h19 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[19]][[1]])
efecte.h20 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[20]][[1]])

```





```

efecte.h41 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[41]][[1]])
efecte.h42 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[42]][[1]])
efecte.h43 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[43]][[1]])
efecte.h44 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[44]][[1]])

mitjana<-
c(mean(efecte.h1),mean(efecte.h2),mean(efecte.h3),mean(efecte.h4),mean
(efecte.h5),mean(efecte.h6),mean(efecte.h7),mean(efecte.h8),
mean(efecte.h9),mean(efecte.h10),mean(efecte.h11),mean(efecte.h12),mea
n(efecte.h13),mean(efecte.h14),mean(efecte.h15),mean(efecte.h16),
mean(efecte.h17),mean(efecte.h18),mean(efecte.h19),mean(efecte.h20),me
an(efecte.h21),mean(efecte.h22),mean(efecte.h23),mean(efecte.h24),mean
(efecte.h25),
mean(efecte.h26),mean(efecte.h27),mean(efecte.h28),mean(efecte.h29),me
an(efecte.h30),mean(efecte.h31),mean(efecte.h32),mean(efecte.h33),mean
(efecte.h34),
mean(efecte.h35),mean(efecte.h36),mean(efecte.h37),mean(efecte.h38),me
an(efecte.h39),mean(efecte.h40),mean(efecte.h41),mean(efecte.h42),mean
(efecte.h43),
mean(efecte.h44))

ic.inf<-
c(quantile(efecte.h1,0.025),quantile(efecte.h2,0.025),quantile(efecte.
h3,0.025),quantile(efecte.h4,0.025),quantile(efecte.h5,0.025),quantile
(efecte.h6,0.025),quantile(efecte.h7,0.025),quantile(efecte.h8,0.025),
quantile(efecte.h9,0.025),quantile(efecte.h10,0.025),quantile(efecte.h
11,0.025),quantile(efecte.h12,0.025),quantile(efecte.h13,0.025),quanti
le(efecte.h14,0.025),quantile(efecte.h15,0.025),quantile(efecte.h16,0.
025),
quantile(efecte.h17,0.025),quantile(efecte.h18,0.025),quantile(efecte.
h19,0.025),quantile(efecte.h20,0.025),quantile(efecte.h21,0.025),quant
ile(efecte.h22,0.025),quantile(efecte.h23,0.025),quantile(efecte.h24,0
.025),quantile(efecte.h25,0.025),
quantile(efecte.h26,0.025),quantile(efecte.h27,0.025),quantile(efecte.
h28,0.025),quantile(efecte.h29,0.025),quantile(efecte.h30,0.025),quant
ile(efecte.h31,0.025),quantile(efecte.h32,0.025),quantile(efecte.h33,0
.025),quantile(efecte.h34,0.025),
quantile(efecte.h35,0.025),quantile(efecte.h36,0.025),quantile(efecte.
h37,0.025),quantile(efecte.h38,0.025),quantile(efecte.h39,0.025),quant
ile(efecte.h40,0.025),quantile(efecte.h41,0.025),quantile(efecte.h42,0
.025),quantile(efecte.h43,0.025),
quantile(efecte.h44,0.025))

ic.sup<-
c(quantile(efecte.h1,0.975),quantile(efecte.h2,0.975),quantile(efecte.
h3,0.975),quantile(efecte.h4,0.975),quantile(efecte.h5,0.975),quantile
(efecte.h6,0.975),quantile(efecte.h7,0.975),quantile(efecte.h8,0.975),
quantile(efecte.h9,0.975),quantile(efecte.h10,0.975),quantile(efecte.h
11,0.975),quantile(efecte.h12,0.975),quantile(efecte.h13,0.975),quanti
le(efecte.h14,0.975),quantile(efecte.h15,0.975),quantile(efecte.h16,0.
975),

```

```

quantile(efecte.h17,0.975),quantile(efecte.h18,0.975),quantile(efecte.
h19,0.975),quantile(efecte.h20,0.975),quantile(efecte.h21,0.975),quant
ile(efecte.h22,0.975),quantile(efecte.h23,0.975),quantile(efecte.h24,0
.975),quantile(efecte.h25,0.975),
quantile(efecte.h26,0.975),quantile(efecte.h27,0.975),quantile(efecte.
h28,0.975),quantile(efecte.h29,0.975),quantile(efecte.h30,0.975),quant
ile(efecte.h31,0.975),quantile(efecte.h32,0.975),quantile(efecte.h33,0
.975),quantile(efecte.h34,0.975),
quantile(efecte.h35,0.975),quantile(efecte.h36,0.975),quantile(efecte.
h37,0.975),quantile(efecte.h38,0.975),quantile(efecte.h39,0.975),quant
ile(efecte.h40,0.975),quantile(efecte.h41,0.975),quantile(efecte.h42,0
.975),quantile(efecte.h43,0.975),
quantile(efecte.h44,0.975))

```

```

plot(1:44,mitjana,ylim=c(min(ic.inf),max(ic.sup)),col="darkmagenta",xli
im=c(0.95,44.05),pch=19,main="Efecte dels centres en la
millora",xlab="Hospitals",ylab="")
abline(h=0,col="darkolivegreen")
points(1:44,ic.inf,pch=95,col="darkmagenta")
points(1:44,ic.sup,pch=95,col="darkmagenta")
#axis(1,seq(1:44),cex.axis=.5)
for (i in 1:44){
  lines(c(i,i),c(ic.inf[i],ic.sup[i]),col="darkmagenta")
}
box("outer",lwd=10,col="lightgoldenrod4")

```

```

## Model 3: Millora Percentatge de compliment de les mesures efectes
fixes unitats
formula = explicativa~temps+tipo+f(unidad,model="iid")
resultat1 = inla(formula, family="gaussian", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE),
data=Datos,verbose=T)

```

```
summary(resultat1)
```

```

resultat1$dic$dic
-mean(resultat1$cpo,na.rm=T)

```

```

plot(resultat1$marginals.fixed$"temps"[,1],resultat1$marginals.fixed$"
temps"[,2],xlab="",ylab="",main="Efecte Temps")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"tipo"[,1],resultat1$marginals.fixed$"t
ipo"[,2],xlab="",ylab="",main="Efecte Hospitales vs CSS")
abline(v=0,col="red")
box("outer",lwd=5)

```

```

efecte.u1 =
inla.rmarginal(1000,resultat1$marginals.random$unidad[names(resultat1$
marginals.random$unidad)[1]][[1]])
efecte.u2 =
inla.rmarginal(1000,resultat1$marginals.random$unidad[names(resultat1$
marginals.random$unidad)[2]][[1]])

```

```

efecte.u3 =
inla.rmarginal(1000,resultat1$marginals.random$unidad[names(resultat1$
marginals.random$unidad)[3]][[1]])
efecte.u4 =
inla.rmarginal(1000,resultat1$marginals.random$unidad[names(resultat1$
marginals.random$unidad)[4]][[1]])
efecte.u5 =
inla.rmarginal(1000,resultat1$marginals.random$unidad[names(resultat1$
marginals.random$unidad)[5]][[1]])

mitjana<-
c(mean(efecte.u1),mean(efecte.u2),mean(efecte.u3),mean(efecte.u4),mean
(efecte.u5))

ic.inf<-
c(quantile(efecte.u1,0.025),quantile(efecte.u2,0.025),quantile(efecte.
u3,0.025),quantile(efecte.u4,0.025),quantile(efecte.u5,0.025))

ic.sup<-
c(quantile(efecte.u1,0.975),quantile(efecte.u2,0.975),quantile(efecte.
u3,0.975),quantile(efecte.u4,0.975),quantile(efecte.u5,0.975))

plot(1:5,mitjana,ylim=c(min(ic.inf),max(ic.sup)),xlim=c(0.95,5.05),col
="darkmagenta",pch=19,main="Efecte de les
unitats",xlab="Unitats",ylab="",axes=F)
abline(h=0,col="darkolivegreen")
points(1:5,ic.inf,pch=95,col="darkmagenta")
points(1:5,ic.sup,pch=95,col="darkmagenta")
axis(1,seq(1:5),c("Unitat 1", "Unitat 2", "Unitat SM", "Unitat
Mèdica", "Unitat Quirúrgica"))
axis(2,seq(-0.1,.1,.02))
for (i in 1:5){
  lines(c(i,i),c(ic.inf[i],ic.sup[i]),col="darkmagenta")
}
box()
box("outer",lwd=10,col="lightgoldenrod4")

## Model 3.BIS: Millora Percentatge de compliment de les mesures
efectes fixes unitats
unidad2<-unidad
Datos<-data.frame(Datos,unidad2)

formula =
explicativa~tipo+f(unidad2,model="iid")+f(unidad,temps,model="iid")
resultat1 = inla(formula, family="gaussian", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE),
data=Datos,verbose=T)

summary(resultat1)

resultat1$dic$dic
-mean(resultat1$cpo,na.rm=T)

```

```

plot(resultat1$marginals.fixed$"temps"[,1],resultat1$marginals.fixed$"
temps"[,2],xlab="",ylab="",main="Efecte Temps")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"tipo"[,1],resultat1$marginals.fixed$"t
ipo"[,2],xlab="",ylab="",main="Efecte Hospitales vs CSS")
abline(v=0,col="red")
box("outer",lwd=5)

efecte.u1 =
inla.rmarginal(1000,resultat1$marginals.random$unidad[names(resultat1$
marginals.random$unidad)[1]][[1]])
efecte.u2 =
inla.rmarginal(1000,resultat1$marginals.random$unidad[names(resultat1$
marginals.random$unidad)[2]][[1]])
efecte.u3 =
inla.rmarginal(1000,resultat1$marginals.random$unidad[names(resultat1$
marginals.random$unidad)[3]][[1]])
efecte.u4 =
inla.rmarginal(1000,resultat1$marginals.random$unidad[names(resultat1$
marginals.random$unidad)[4]][[1]])
efecte.u5 =
inla.rmarginal(1000,resultat1$marginals.random$unidad[names(resultat1$
marginals.random$unidad)[5]][[1]])

mitjana<-
c(mean(efecte.u1),mean(efecte.u2),mean(efecte.u3),mean(efecte.u4),mean
(efecte.u5))

ic.inf<-
c(quantile(efecte.u1,0.025),quantile(efecte.u2,0.025),quantile(efecte.
u3,0.025),quantile(efecte.u4,0.025),quantile(efecte.u5,0.025))

ic.sup<-
c(quantile(efecte.u1,0.975),quantile(efecte.u2,0.975),quantile(efecte.
u3,0.975),quantile(efecte.u4,0.975),quantile(efecte.u5,0.975))

plot(1:5,mitjana,ylim=c(min(ic.inf),max(ic.sup)),xlim=c(0.95,5.05),col
="darkmagenta",pch=19,main="Efecte de la millora en les
unitats",xlab="Unitats",ylab="",axes=F)
abline(h=0,col="darkolivegreen")
points(1:5,ic.inf,pch=95,col="darkmagenta")
points(1:5,ic.sup,pch=95,col="darkmagenta")
axis(1,seq(1:5),c("Unitat 1", "Unitat 2", "Unitat SM", "Unitat
Mèdica", "Unitat Quirúrgica"))
axis(2,seq(-0.1,.1,.02))
for (i in 1:5){
  lines(c(i,i),c(ic.inf[i],ic.sup[i]),col="darkmagenta")
}
box()
box("outer",lwd=10,col="lightgoldenrod4")

```

```

## Model 4: Millora Percentatge de compliment de les mesures efectes
fixes unitat dins hospital
unidad3<-hospital*as.numeric(unidad)

Datos<-data.frame(Datos,unidad3)

formula =
explicativa~temps+tipo+f(hospital,model="iid")+f(unidad3,model="iid")
resultat1 = inla(formula, family="gaussian", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE),
data=Datos,verbose=T)

summary(resultat1)

resultat1$dic$dic
-mean(resultat1$cpo,na.rm=T)

par(mfrow=c(1,2),oma=c(4,2,4,2))
plot(resultat1$marginals.fixed$"temps"[,1],resultat1$marginals.fixed$
"temps"[,2],xlab="",ylab="",main="Efecte Temps",pch=19,col="darkgreen")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"tipo"[,1],resultat1$marginals.fixed$"t
ipo"[,2],xlab="",ylab="",main="Efecte Hospitals vs
CSS",pch=19,col="darkred")
abline(v=0,col="red")
box("outer",lwd=10,col="lightgoldenrod4")

```

##### TAXA DE CAIGUDES #####

#### SENSE TENIR EN COMPTE LA TEMPO-DEPENDÈNCIA

## Dades

```

explicativa<- Percent_mean
temps<- as.numeric(Quinzena)
obs<- NumCaidas_sum
esp<- NumPacientes_sum
programa<-x1.ProgramaPrevecio
implantacio<-x2.Implantacio
any<-rep(NA,nrow(datos))
any[which(x3.AnyImplantacio=="1990")]<-1990
any[which(x3.AnyImplantacio=="1994")]<-1994
any[which(x3.AnyImplantacio=="1996")]<-1996
any[which(x3.AnyImplantacio=="1998")]<-1998
any[which(x3.AnyImplantacio=="1999")]<-1999
any[which(x3.AnyImplantacio=="2000")]<-2000
any[which(x3.AnyImplantacio=="2001")]<-2001
any[which(x3.AnyImplantacio=="2002")]<-2002
any[which(x3.AnyImplantacio=="2003")]<-2003
any[which(x3.AnyImplantacio=="2004")]<-2004
any[which(x3.AnyImplantacio=="2005")]<-2005

```

```

any[which(x3.AnyImplantacio=="2007")]<-2007
valoracio<-x4.ValoracioRisc
difusio<-x5.Difusio
tipus<-as.numeric(Tabla)-1## 1 = hospitals; 0 = css
outlier<-rep(NA,nrow(datos))
outlier[which(tanpermil>20)]<-1
outlier[which(tanpermil<20)]<-0

Datos<-data.frame(obs,esp,
explicativa=explicativa,temps=temps,programa,implantacio,any,valoracio
,difusio,tipus,outlier)

## Model 1: Efectes fixos
formula = obs~ explicativa+temps+programa+tipus
resultat1 = inla(formula, family="poisson", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
), data=Datos,E=esp,verbose=T)

summary(resultat1)

resultat1$dic$dic
-mean(log(resultat1$cpo),na.rm=T)
-mean(log(resultat1$cpo[resultat1$cpo>0]),na.rm=T)

formula = obs~
explicativa+temps+tipus+implantacio+any+valoracio+difusio
resultat1 = inla(formula, family="poisson", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
), data=Datos,E=esp,verbose=T)

summary(resultat1)

resultat1$dic$dic
-mean(log(resultat1$cpo),na.rm=T)
-mean(log(resultat1$cpo[resultat1$cpo>0]),na.rm=T)

par(mfrow=c(2,4),oma=c(4,2,4,2))
plot(resultat1$marginals.fixed$"explicativa"[,1],resultat1$marginals.f
ixed$"explicativa"[,2],xlab="",ylab="",main="Efecte
Mesures",pch=19,col="darkgreen")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"temps"[,1],resultat1$marginals.fixed$
temps[,2],xlab="",ylab="",main="Efecte Temps",pch=19,col="darkred")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"programa"[,1],resultat1$marginals.fixe
d$"programa"[,2],xlab="",ylab="",main="Efecte
Programa",pch=19,col="darkred")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"implantacio"[,1],resultat1$marginals.f
ixed$"implantacio"[,2],xlab="",ylab="",main="Efecte Implantació a tot
el centre",pch=19,col="darkred")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"any"[,1],resultat1$marginals.fixed$"an
y"[,2],xlab="",ylab="",main="Efecte any
d'implantació",pch=19,col="darkred")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"valoracio"[,1],resultat1$marginals.fix
ed$"valoracio"[,2],xlab="",ylab="",main="Efecte Valoració
Risc",pch=19,col="darkred")
abline(v=0,col="red")

```

```

plot(resultat1$marginals.fixed$"difusio"[,1],resultat1$marginals.fixed
$"difusio"[,2],xlab="",ylab="",main="Efecte Difondre Resultats
",pch=19,col="darkred")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"tipus"[,1],resultat1$marginals.fixed$"
tipus"[,2],xlab="",ylab="",main="Efecte Hospital vs
CSS",pch=19,col="darkred")
abline(v=0,col="red")
box("outer",lwd=10,col="lightgoldenrod4")

```

##### TENINT EN COMPTE LA TEMPO-DEPENDÈNCIA#####

```
explicativa<- Percent_mean*as.numeric(Quinzena)
```

```

Datos<-data.frame(obs,esp,
explicativa=explicativa,temps=temps,programa,implantacio,any,valoracio
,difusio,tipus,outlier)

```

```

## Model 1: Efectes fixos
formula = obs~ explicativa+temps+programa+tipus+outlier
resultat1 = inla(formula, family="poisson", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
), data=Datos,E=esp,verbose=T)

```

```
summary(resultat1)
```

```

resultat1$dic$dic
-mean(log(resultat1$cpo),na.rm=T)
-mean(log(resultat1$cpo[resultat1$cpo>0]),na.rm=T)

```

```

formula = obs~ explicativa+temps+tipus+outlier+implantacio+any+difusio
resultat1 = inla(formula, family="poisson", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
), data=Datos,E=esp,verbose=T)

```

```
summary(resultat1)
```

```

resultat1$dic$dic
-mean(log(resultat1$cpo),na.rm=T)
-mean(log(resultat1$cpo[resultat1$cpo>0]),na.rm=T)

```

```

par(mfrow=c(2,4),oma=c(4,2,4,2))
plot(resultat1$marginals.fixed$"explicativa"[,1],resultat1$marginals.f
ixed$"explicativa"[,2],xlab="",ylab="",main="Efecte
Mesures",pch=19,col="darkgreen")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"temps"[,1],resultat1$marginals.fixed$"
temps"[,2],xlab="",ylab="",main="Efecte Temps",pch=19,col="darkred")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"programa"[,1],resultat1$marginals.fixe
d$"programa"[,2],xlab="",ylab="",main="Efecte
Programa",pch=19,col="darkred")
abline(v=0,col="red")

```

```

plot(resultat1$marginals.fixed$"implantacio"[,1],resultat1$marginals.f
ixed$"implantacio"[,2],xlab="",ylab="",main="Efecte Implantació a tot
el centre",pch=19,col="darkred")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"any"[,1],resultat1$marginals.fixed$"an
y"[,2],xlab="",ylab="",main="Efecte any
d'implantació",pch=19,col="darkred")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"valoracio"[,1],resultat1$marginals.fix
ed$"valoracio"[,2],xlab="",ylab="",main="Efecte Valoració
Risc",pch=19,col="darkred")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"difusio"[,1],resultat1$marginals.fixed
$"difusio"[,2],xlab="",ylab="",main="Efecte Difondre Resultats
",pch=19,col="darkred")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"tipus"[,1],resultat1$marginals.fixed$"
tipus"[,2],xlab="",ylab="",main="Efecte Hospital vs
CSS",pch=19,col="darkred")
abline(v=0,col="red")
box("outer",lwd=10,col="lightgoldenrod4")

```

```

## Model 2: Efectes mixtes. Hospital efecte aleatori

```

```

hospital<-IdHospital
hospital2<-hospital
hospital3<-hospital
#temps<- as.numeric(Quinzena)
#unidad<-as.factor(as.numeric(Unidad))

```

```

Datos<-data.frame(Datos,hospital2,hospital3)

```

```

formula = obs~ f(hospital,model="iid")+explicativa+temps+outlier
formula = obs~
f(hospital,model="iid")+f(hospital2,explicativa,model="iid")+f(hospita
l3,temps,model="iid")+outlier
resultat1 = inla(formula, family="poisson", control.compute =
list(dic=T),control.predictor=list(compute=TRUE,cdf=c(log(1))),
data=Datos,E=esp,verbose=T)

```

```

summary(resultat1)

```

```

resultat1$dic$dic
-mean(log(resultat1$cpo),na.rm=T)
-mean(log(resultat1$cpo[resultat1$cpo>0]),na.rm=T)

```

```

par(mfrow=c(2,4),oma=c(4,2,4,2))
plot(resultat1$marginals.fixed$"explicativa"[,1],resultat1$marginals.f
ixed$"explicativa"[,2],xlab="",ylab="",main="Efecte
Mesures",pch=19,col="darkgreen")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"temps"[,1],resultat1$marginals.fixed$"
temps"[,2],xlab="",ylab="",main="Efecte Temps",pch=19,col="darkred")
abline(v=0,col="red")

```



```

plot(resultat1$marginals.fixed$"programa"[,1],resultat1$marginals.fixed$"programa"[,2],xlab="",ylab="",main="Efecte Programa",pch=19,col="darkred")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"implantacio"[,1],resultat1$marginals.fixed$"implantacio"[,2],xlab="",ylab="",main="Efecte Implantació a tot el centre",pch=19,col="darkred")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"any"[,1],resultat1$marginals.fixed$"any"[,2],xlab="",ylab="",main="Efecte any d'implantació",pch=19,col="darkred")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"valoracio"[,1],resultat1$marginals.fixed$"valoracio"[,2],xlab="",ylab="",main="Efecte Valoració Risc",pch=19,col="darkred")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"difusio"[,1],resultat1$marginals.fixed$"difusio"[,2],xlab="",ylab="",main="Efecte Difondre Resultats",pch=19,col="darkred")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"tipus"[,1],resultat1$marginals.fixed$"tipus"[,2],xlab="",ylab="",main="Efecte Hospital vs CSS",pch=19,col="darkred")
abline(v=0,col="red")
box("outer",lwd=10,col="lightgoldenrod4")

```

```

efecte.h1 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat1$marginals.random$hospital)[1]][[1]])
efecte.h2 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat1$marginals.random$hospital)[2]][[1]])
efecte.h3 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat1$marginals.random$hospital)[3]][[1]])
efecte.h4 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat1$marginals.random$hospital)[4]][[1]])
efecte.h5 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat1$marginals.random$hospital)[5]][[1]])
efecte.h6 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat1$marginals.random$hospital)[6]][[1]])
efecte.h7 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat1$marginals.random$hospital)[7]][[1]])
efecte.h8 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat1$marginals.random$hospital)[8]][[1]])
efecte.h9 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat1$marginals.random$hospital)[9]][[1]])
efecte.h10 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat1$marginals.random$hospital)[10]][[1]])
efecte.h11 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat1$marginals.random$hospital)[11]][[1]])

```



```

efecte.h32 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[32]][[1]])
efecte.h33 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[33]][[1]])
efecte.h34 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[34]][[1]])
efecte.h35 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[35]][[1]])
efecte.h36 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[36]][[1]])
efecte.h37 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[37]][[1]])
efecte.h38 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[38]][[1]])
efecte.h39 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[39]][[1]])
efecte.h40 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[40]][[1]])
efecte.h41 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[41]][[1]])
efecte.h42 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[42]][[1]])
efecte.h43 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[43]][[1]])
efecte.h44 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[44]][[1]])

```

```

mitjana<-
c(mean(efecte.h1),mean(efecte.h2),mean(efecte.h3),mean(efecte.h4),mean
(efecte.h5),mean(efecte.h6),mean(efecte.h7),mean(efecte.h8),
mean(efecte.h9),mean(efecte.h10),mean(efecte.h11),mean(efecte.h12),mea
n(efecte.h13),mean(efecte.h14),mean(efecte.h15),mean(efecte.h16),
mean(efecte.h17),mean(efecte.h18),mean(efecte.h19),mean(efecte.h20),me
an(efecte.h21),mean(efecte.h22),mean(efecte.h23),mean(efecte.h24),mean
(efecte.h25),
mean(efecte.h26),mean(efecte.h27),mean(efecte.h28),mean(efecte.h29),me
an(efecte.h30),mean(efecte.h31),mean(efecte.h32),mean(efecte.h33),mean
(efecte.h34),
mean(efecte.h35),mean(efecte.h36),mean(efecte.h37),mean(efecte.h38),me
an(efecte.h39),mean(efecte.h40),mean(efecte.h41),mean(efecte.h42),mean
(efecte.h43),
mean(efecte.h44))

```

```

ic.inf<-
c(quantile(efecte.h1,0.025),quantile(efecte.h2,0.025),quantile(efecte.
h3,0.025),quantile(efecte.h4,0.025),quantile(efecte.h5,0.025),quantile
(efecte.h6,0.025),quantile(efecte.h7,0.025),quantile(efecte.h8,0.025),

```

```

quantile(efecte.h9,0.025),quantile(efecte.h10,0.025),quantile(efecte.h
11,0.025),quantile(efecte.h12,0.025),quantile(efecte.h13,0.025),quanti
le(efecte.h14,0.025),quantile(efecte.h15,0.025),quantile(efecte.h16,0.
025),
quantile(efecte.h17,0.025),quantile(efecte.h18,0.025),quantile(efecte.
h19,0.025),quantile(efecte.h20,0.025),quantile(efecte.h21,0.025),quant
ile(efecte.h22,0.025),quantile(efecte.h23,0.025),quantile(efecte.h24,0
.025),quantile(efecte.h25,0.025),
quantile(efecte.h26,0.025),quantile(efecte.h27,0.025),quantile(efecte.
h28,0.025),quantile(efecte.h29,0.025),quantile(efecte.h30,0.025),quant
ile(efecte.h31,0.025),quantile(efecte.h32,0.025),quantile(efecte.h33,0
.025),quantile(efecte.h34,0.025),
quantile(efecte.h35,0.025),quantile(efecte.h36,0.025),quantile(efecte.
h37,0.025),quantile(efecte.h38,0.025),quantile(efecte.h39,0.025),quant
ile(efecte.h40,0.025),quantile(efecte.h41,0.025),quantile(efecte.h42,0
.025),quantile(efecte.h43,0.025),
quantile(efecte.h44,0.025))

```

```

ic.sup<-
c(quantile(efecte.h1,0.975),quantile(efecte.h2,0.975),quantile(efecte.
h3,0.975),quantile(efecte.h4,0.975),quantile(efecte.h5,0.975),quantile
(efecte.h6,0.975),quantile(efecte.h7,0.975),quantile(efecte.h8,0.975),
quantile(efecte.h9,0.975),quantile(efecte.h10,0.975),quantile(efecte.h
11,0.975),quantile(efecte.h12,0.975),quantile(efecte.h13,0.975),quanti
le(efecte.h14,0.975),quantile(efecte.h15,0.975),quantile(efecte.h16,0.
975),
quantile(efecte.h17,0.975),quantile(efecte.h18,0.975),quantile(efecte.
h19,0.975),quantile(efecte.h20,0.975),quantile(efecte.h21,0.975),quant
ile(efecte.h22,0.975),quantile(efecte.h23,0.975),quantile(efecte.h24,0
.975),quantile(efecte.h25,0.975),
quantile(efecte.h26,0.975),quantile(efecte.h27,0.975),quantile(efecte.
h28,0.975),quantile(efecte.h29,0.975),quantile(efecte.h30,0.975),quant
ile(efecte.h31,0.975),quantile(efecte.h32,0.975),quantile(efecte.h33,0
.975),quantile(efecte.h34,0.975),
quantile(efecte.h35,0.975),quantile(efecte.h36,0.975),quantile(efecte.
h37,0.975),quantile(efecte.h38,0.975),quantile(efecte.h39,0.975),quant
ile(efecte.h40,0.975),quantile(efecte.h41,0.975),quantile(efecte.h42,0
.975),quantile(efecte.h43,0.975),
quantile(efecte.h44,0.975))

```

```

par(mfrow=c(3,1))
plot(1:44,mitjana,ylim=c(min(ic.inf),max(ic.sup)),col="darkmagenta",xli
m=c(0.95,44.05),pch=19,main="Efecte dels centres en la taxa de
caigudes",xlab="Hospitals",ylab="")
abline(h=0,col="darkolivegreen")
points(1:44,ic.inf,pch=95,col="darkmagenta")
points(1:44,ic.sup,pch=95,col="darkmagenta")
#axis(1,seq(1:44),cex.axis=.5)
for (i in 1:44){
  lines(c(i,i),c(ic.inf[i],ic.sup[i]),col="darkmagenta")
}
box("outer",lwd=10,col="lightgoldenrod4")

```

```

efecte.h1 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[1]][[1]])
efecte.h2 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[2]][[1]])

```

```

efecte.h3 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[3]][[1]])
efecte.h4 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[4]][[1]])
efecte.h5 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[5]][[1]])
efecte.h6 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[6]][[1]])
efecte.h7 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[7]][[1]])
efecte.h8 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[8]][[1]])
efecte.h9 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[9]][[1]])
efecte.h10 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[10]][[1]])
efecte.h11 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[11]][[1]])
efecte.h12 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[12]][[1]])
efecte.h13 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[13]][[1]])
efecte.h14 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[14]][[1]])
efecte.h15 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[15]][[1]])
efecte.h16 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[16]][[1]])
efecte.h17 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[17]][[1]])
efecte.h18 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[18]][[1]])
efecte.h19 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[19]][[1]])
efecte.h20 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[20]][[1]])
efecte.h21 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[21]][[1]])
efecte.h22 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[22]][[1]])

```



```

efecte.h43 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[43]][[1]])
efecte.h44 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[44]][[1]])

mitjana<-
c(mean(efecte.h1),mean(efecte.h2),mean(efecte.h3),mean(efecte.h4),mean
(efecte.h5),mean(efecte.h6),mean(efecte.h7),mean(efecte.h8),
mean(efecte.h9),mean(efecte.h10),mean(efecte.h11),mean(efecte.h12),mea
n(efecte.h13),mean(efecte.h14),mean(efecte.h15),mean(efecte.h16),
mean(efecte.h17),mean(efecte.h18),mean(efecte.h19),mean(efecte.h20),me
an(efecte.h21),mean(efecte.h22),mean(efecte.h23),mean(efecte.h24),mean
(efecte.h25),
mean(efecte.h26),mean(efecte.h27),mean(efecte.h28),mean(efecte.h29),me
an(efecte.h30),mean(efecte.h31),mean(efecte.h32),mean(efecte.h33),mean
(efecte.h34),
mean(efecte.h35),mean(efecte.h36),mean(efecte.h37),mean(efecte.h38),me
an(efecte.h39),mean(efecte.h40),mean(efecte.h41),mean(efecte.h42),mean
(efecte.h43),
mean(efecte.h44))

ic.inf<-
c(quantile(efecte.h1,0.025),quantile(efecte.h2,0.025),quantile(efecte.
h3,0.025),quantile(efecte.h4,0.025),quantile(efecte.h5,0.025),quantile
(efecte.h6,0.025),quantile(efecte.h7,0.025),quantile(efecte.h8,0.025),
quantile(efecte.h9,0.025),quantile(efecte.h10,0.025),quantile(efecte.h
11,0.025),quantile(efecte.h12,0.025),quantile(efecte.h13,0.025),quanti
le(efecte.h14,0.025),quantile(efecte.h15,0.025),quantile(efecte.h16,0.
025),
quantile(efecte.h17,0.025),quantile(efecte.h18,0.025),quantile(efecte.
h19,0.025),quantile(efecte.h20,0.025),quantile(efecte.h21,0.025),quant
ile(efecte.h22,0.025),quantile(efecte.h23,0.025),quantile(efecte.h24,0
.025),quantile(efecte.h25,0.025),
quantile(efecte.h26,0.025),quantile(efecte.h27,0.025),quantile(efecte.
h28,0.025),quantile(efecte.h29,0.025),quantile(efecte.h30,0.025),quant
ile(efecte.h31,0.025),quantile(efecte.h32,0.025),quantile(efecte.h33,0
.025),quantile(efecte.h34,0.025),
quantile(efecte.h35,0.025),quantile(efecte.h36,0.025),quantile(efecte.
h37,0.025),quantile(efecte.h38,0.025),quantile(efecte.h39,0.025),quant
ile(efecte.h40,0.025),quantile(efecte.h41,0.025),quantile(efecte.h42,0
.025),quantile(efecte.h43,0.025),
quantile(efecte.h44,0.025))

ic.sup<-
c(quantile(efecte.h1,0.975),quantile(efecte.h2,0.975),quantile(efecte.
h3,0.975),quantile(efecte.h4,0.975),quantile(efecte.h5,0.975),quantile
(efecte.h6,0.975),quantile(efecte.h7,0.975),quantile(efecte.h8,0.975),
quantile(efecte.h9,0.975),quantile(efecte.h10,0.975),quantile(efecte.h
11,0.975),quantile(efecte.h12,0.975),quantile(efecte.h13,0.975),quanti
le(efecte.h14,0.975),quantile(efecte.h15,0.975),quantile(efecte.h16,0.
975),
quantile(efecte.h17,0.975),quantile(efecte.h18,0.975),quantile(efecte.
h19,0.975),quantile(efecte.h20,0.975),quantile(efecte.h21,0.975),quant
ile(efecte.h22,0.975),quantile(efecte.h23,0.975),quantile(efecte.h24,0
.975),quantile(efecte.h25,0.975),
quantile(efecte.h26,0.975),quantile(efecte.h27,0.975),quantile(efecte.
h28,0.975),quantile(efecte.h29,0.975),quantile(efecte.h30,0.975),quant

```

```

ile(efecte.h31,0.975),quantile(efecte.h32,0.975),quantile(efecte.h33,0
.975),quantile(efecte.h34,0.975),
quantile(efecte.h35,0.975),quantile(efecte.h36,0.975),quantile(efecte.
h37,0.975),quantile(efecte.h38,0.975),quantile(efecte.h39,0.975),quant
ile(efecte.h40,0.975),quantile(efecte.h41,0.975),quantile(efecte.h42,0
.975),quantile(efecte.h43,0.975),
quantile(efecte.h44,0.975))

```

```

plot(1:44,mitjana,ylim=c(min(ic.inf),max(ic.sup)),col="darkmagenta",xl
im=c(0.95,44.05),pch=19,main="Mesures associades a l'Efecte dels
centres en la taxa de caigudes",xlab="Hospitals",ylab="")
abline(h=0,col="darkolivegreen")
points(1:44,ic.inf,pch=95,col="darkmagenta")
points(1:44,ic.sup,pch=95,col="darkmagenta")
#axis(1,seq(1:44),cex.axis=.5)
for (i in 1:44){
  lines(c(i,i),c(ic.inf[i],ic.sup[i]),col="darkmagenta")
}
box("outer",lwd=10,col="lightgoldenrod4")

```

```

efecte.h1 =
inla.rmarginal(1000,resultat1$marginals.random$hospital3[names(resulta
t1$marginals.random$hospital3)[1]][[1]])
efecte.h2 =
inla.rmarginal(1000,resultat1$marginals.random$hospital3[names(resulta
t1$marginals.random$hospital3)[2]][[1]])
efecte.h3 =
inla.rmarginal(1000,resultat1$marginals.random$hospital3[names(resulta
t1$marginals.random$hospital3)[3]][[1]])
efecte.h4 =
inla.rmarginal(1000,resultat1$marginals.random$hospital3[names(resulta
t1$marginals.random$hospital3)[4]][[1]])
efecte.h5 =
inla.rmarginal(1000,resultat1$marginals.random$hospital3[names(resulta
t1$marginals.random$hospital3)[5]][[1]])
efecte.h6 =
inla.rmarginal(1000,resultat1$marginals.random$hospital3[names(resulta
t1$marginals.random$hospital3)[6]][[1]])
efecte.h7 =
inla.rmarginal(1000,resultat1$marginals.random$hospital3[names(resulta
t1$marginals.random$hospital3)[7]][[1]])
efecte.h8 =
inla.rmarginal(1000,resultat1$marginals.random$hospital3[names(resulta
t1$marginals.random$hospital3)[8]][[1]])
efecte.h9 =
inla.rmarginal(1000,resultat1$marginals.random$hospital3[names(resulta
t1$marginals.random$hospital3)[9]][[1]])
efecte.h10 =
inla.rmarginal(1000,resultat1$marginals.random$hospital3[names(resulta
t1$marginals.random$hospital3)[10]][[1]])
efecte.h11 =
inla.rmarginal(1000,resultat1$marginals.random$hospital3[names(resulta
t1$marginals.random$hospital3)[11]][[1]])
efecte.h12 =
inla.rmarginal(1000,resultat1$marginals.random$hospital3[names(resulta
t1$marginals.random$hospital3)[12]][[1]])
efecte.h13 =
inla.rmarginal(1000,resultat1$marginals.random$hospital3[names(resulta
t1$marginals.random$hospital3)[13]][[1]])

```





```

efecte.h34 =
inla.rmarginal(1000,resultat1$marginals.random$hospital3[names(resulta
t1$marginals.random$hospital3)[34]][[1]])
efecte.h35 =
inla.rmarginal(1000,resultat1$marginals.random$hospital3[names(resulta
t1$marginals.random$hospital3)[35]][[1]])
efecte.h36 =
inla.rmarginal(1000,resultat1$marginals.random$hospital3[names(resulta
t1$marginals.random$hospital3)[36]][[1]])
efecte.h37 =
inla.rmarginal(1000,resultat1$marginals.random$hospital3[names(resulta
t1$marginals.random$hospital3)[37]][[1]])
efecte.h38 =
inla.rmarginal(1000,resultat1$marginals.random$hospital3[names(resulta
t1$marginals.random$hospital3)[38]][[1]])
efecte.h39 =
inla.rmarginal(1000,resultat1$marginals.random$hospital3[names(resulta
t1$marginals.random$hospital3)[39]][[1]])
efecte.h40 =
inla.rmarginal(1000,resultat1$marginals.random$hospital3[names(resulta
t1$marginals.random$hospital3)[40]][[1]])
efecte.h41 =
inla.rmarginal(1000,resultat1$marginals.random$hospital3[names(resulta
t1$marginals.random$hospital3)[41]][[1]])
efecte.h42 =
inla.rmarginal(1000,resultat1$marginals.random$hospital3[names(resulta
t1$marginals.random$hospital3)[42]][[1]])
efecte.h43 =
inla.rmarginal(1000,resultat1$marginals.random$hospital3[names(resulta
t1$marginals.random$hospital3)[43]][[1]])
efecte.h44 =
inla.rmarginal(1000,resultat1$marginals.random$hospital3[names(resulta
t1$marginals.random$hospital3)[44]][[1]])

```

```

mitjana<-
c(mean(efecte.h1),mean(efecte.h2),mean(efecte.h3),mean(efecte.h4),mean
(efecte.h5),mean(efecte.h6),mean(efecte.h7),mean(efecte.h8),
mean(efecte.h9),mean(efecte.h10),mean(efecte.h11),mean(efecte.h12),mea
n(efecte.h13),mean(efecte.h14),mean(efecte.h15),mean(efecte.h16),
mean(efecte.h17),mean(efecte.h18),mean(efecte.h19),mean(efecte.h20),me
an(efecte.h21),mean(efecte.h22),mean(efecte.h23),mean(efecte.h24),mean
(efecte.h25),
mean(efecte.h26),mean(efecte.h27),mean(efecte.h28),mean(efecte.h29),me
an(efecte.h30),mean(efecte.h31),mean(efecte.h32),mean(efecte.h33),mean
(efecte.h34),
mean(efecte.h35),mean(efecte.h36),mean(efecte.h37),mean(efecte.h38),me
an(efecte.h39),mean(efecte.h40),mean(efecte.h41),mean(efecte.h42),mean
(efecte.h43),
mean(efecte.h44))

```

```

ic.inf<-
c(quantile(efecte.h1,0.025),quantile(efecte.h2,0.025),quantile(efecte.
h3,0.025),quantile(efecte.h4,0.025),quantile(efecte.h5,0.025),quantile
(efecte.h6,0.025),quantile(efecte.h7,0.025),quantile(efecte.h8,0.025),
quantile(efecte.h9,0.025),quantile(efecte.h10,0.025),quantile(efecte.h
11,0.025),quantile(efecte.h12,0.025),quantile(efecte.h13,0.025),quanti
le(efecte.h14,0.025),quantile(efecte.h15,0.025),quantile(efecte.h16,0.
025),
quantile(efecte.h17,0.025),quantile(efecte.h18,0.025),quantile(efecte.
h19,0.025),quantile(efecte.h20,0.025),quantile(efecte.h21,0.025),quant

```

```

ile(efecte.h22,0.025),quantile(efecte.h23,0.025),quantile(efecte.h24,0
.025),quantile(efecte.h25,0.025),
quantile(efecte.h26,0.025),quantile(efecte.h27,0.025),quantile(efecte.
h28,0.025),quantile(efecte.h29,0.025),quantile(efecte.h30,0.025),quant
ile(efecte.h31,0.025),quantile(efecte.h32,0.025),quantile(efecte.h33,0
.025),quantile(efecte.h34,0.025),
quantile(efecte.h35,0.025),quantile(efecte.h36,0.025),quantile(efecte.
h37,0.025),quantile(efecte.h38,0.025),quantile(efecte.h39,0.025),quant
ile(efecte.h40,0.025),quantile(efecte.h41,0.025),quantile(efecte.h42,0
.025),quantile(efecte.h43,0.025),
quantile(efecte.h44,0.025))

```

```

ic.sup<-
c(quantile(efecte.h1,0.975),quantile(efecte.h2,0.975),quantile(efecte.
h3,0.975),quantile(efecte.h4,0.975),quantile(efecte.h5,0.975),quantile
(efecte.h6,0.975),quantile(efecte.h7,0.975),quantile(efecte.h8,0.975),
quantile(efecte.h9,0.975),quantile(efecte.h10,0.975),quantile(efecte.h
11,0.975),quantile(efecte.h12,0.975),quantile(efecte.h13,0.975),quanti
le(efecte.h14,0.975),quantile(efecte.h15,0.975),quantile(efecte.h16,0.
975),
quantile(efecte.h17,0.975),quantile(efecte.h18,0.975),quantile(efecte.
h19,0.975),quantile(efecte.h20,0.975),quantile(efecte.h21,0.975),quant
ile(efecte.h22,0.975),quantile(efecte.h23,0.975),quantile(efecte.h24,0
.975),quantile(efecte.h25,0.975),
quantile(efecte.h26,0.975),quantile(efecte.h27,0.975),quantile(efecte.
h28,0.975),quantile(efecte.h29,0.975),quantile(efecte.h30,0.975),quant
ile(efecte.h31,0.975),quantile(efecte.h32,0.975),quantile(efecte.h33,0
.975),quantile(efecte.h34,0.975),
quantile(efecte.h35,0.975),quantile(efecte.h36,0.975),quantile(efecte.
h37,0.975),quantile(efecte.h38,0.975),quantile(efecte.h39,0.975),quant
ile(efecte.h40,0.975),quantile(efecte.h41,0.975),quantile(efecte.h42,0
.975),quantile(efecte.h43,0.975),
quantile(efecte.h44,0.975))

```

```

plot(1:44,mitjana,ylim=c(min(ic.inf),max(ic.sup)),col="darkmagenta",xli
im=c(0.95,44.05),pch=19,main="Temps associat a l'Efecte dels centres
en la taxa de caigudes",xlab="Hospitals",ylab="")
abline(h=0,col="darkolivegreen")
points(1:44,ic.inf,pch=95,col="darkmagenta")
points(1:44,ic.sup,pch=95,col="darkmagenta")
#axis(1,seq(1:44),cex.axis=.5)
for (i in 1:44){
  lines(c(i,i),c(ic.inf[i],ic.sup[i]),col="darkmagenta")
}
box("outer",lwd=10,col="lightgoldenrod4")

```

## Model 2: Efectes mixtes. Hospital efecte aleatori

```

unidad<-as.factor(as.numeric(Unidad))
unidad2<-unidad
unidad3<-unidad
Datos<-data.frame(Datos,unidad2,unidad3)

formula = obs~
f(unidad,model="iid")+explicativa+temps+programa+outlier

```

```

formula = obs~
f(unidad,model="iid")+f(unidad2,explicativa,model="iid")+f(unidad3,tem
ps,model="iid")+programa+outlier
resultat1 = inla(formula, family="poisson", control.compute =
list(dic=T),control.predictor=list(compute=TRUE,cdf=c(log(1))),
data=Datos,E=esp,verbose=T)

formula = obs~
f(unidad,model="iid")+explicativa+temps+any+valoracio+difusio+outlier
resultat1 = inla(formula, family="poisson", control.compute =
list(dic=T),control.predictor=list(compute=TRUE,cdf=c(log(1))),
data=Datos,E=esp,verbose=T)

summary(resultat1)

resultat1$dic$dic
-mean(log(resultat1$cpo),na.rm=T)
-mean(log(resultat1$cpo[resultat1$cpo>0]),na.rm=T)

par(mfrow=c(2,4),oma=c(4,2,4,2))
plot(resultat1$marginals.fixed$"explicativa"[,1],resultat1$marginals.f
ixed$"explicativa"[,2],xlab="",ylab="",main="Efecte
Mesures",pch=19,col="darkgreen")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"temps"[,1],resultat1$marginals.fixed$
temps[,2],xlab="",ylab="",main="Efecte Temps",pch=19,col="darkred")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"programa"[,1],resultat1$marginals.fixe
d$"programa"[,2],xlab="",ylab="",main="Efecte
Programa",pch=19,col="darkred")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"implantacio"[,1],resultat1$marginals.f
ixed$"implantacio"[,2],xlab="",ylab="",main="Efecte Implantació a tot
el centre",pch=19,col="darkred")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"any"[,1],resultat1$marginals.fixed$"an
y"[,2],xlab="",ylab="",main="Efecte any
d'implantació",pch=19,col="darkred")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"valoracio"[,1],resultat1$marginals.fixe
d$"valoracio"[,2],xlab="",ylab="",main="Efecte Valoració
Risc",pch=19,col="darkred")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"difusio"[,1],resultat1$marginals.fixed
$"difusio"[,2],xlab="",ylab="",main="Efecte Difondre Resultats
",pch=19,col="darkred")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"tipus"[,1],resultat1$marginals.fixed$
tipus[,2],xlab="",ylab="",main="Efecte Hospital vs
CSS",pch=19,col="darkred")
abline(v=0,col="red")
box("outer",lwd=10,col="lightgoldenrod4")

efecte.u1 =
inla.rmarginal(1000,resultat1$marginals.random$unidad[names(resultat1$
marginals.random$unidad)[1]][[1]])
efecte.u2 =
inla.rmarginal(1000,resultat1$marginals.random$unidad[names(resultat1$
marginals.random$unidad)[2]][[1]])

```

```

efecte.u3 =
inla.rmarginal(1000,resultat1$marginals.random$unidad[names(resultat1$
marginals.random$unidad)[3]][[1]])
efecte.u4 =
inla.rmarginal(1000,resultat1$marginals.random$unidad[names(resultat1$
marginals.random$unidad)[4]][[1]])
efecte.u5 =
inla.rmarginal(1000,resultat1$marginals.random$unidad[names(resultat1$
marginals.random$unidad)[5]][[1]])

mitjana<-
c(mean(efecte.u1),mean(efecte.u2),mean(efecte.u3),mean(efecte.u4),mean
(efecte.u5))

ic.inf<-
c(quantile(efecte.u1,0.025),quantile(efecte.u2,0.025),quantile(efecte.
u3,0.025),quantile(efecte.u4,0.025),quantile(efecte.u5,0.025))

ic.sup<-
c(quantile(efecte.u1,0.975),quantile(efecte.u2,0.975),quantile(efecte.
u3,0.975),quantile(efecte.u4,0.975),quantile(efecte.u5,0.975))

par(mfrow=c(3,1))
plot(1:5,mitjana,ylim=c(min(ic.inf),max(ic.sup)),xlim=c(0.95,5.05),col
="darkmagenta",pch=19,main="Efecte de les unitats en la taxa de
caigudes",xlab="Unitats",ylab="",axes=F)
abline(h=0,col="darkolivegreen")
points(1:5,ic.inf,pch=95,col="darkmagenta")
points(1:5,ic.sup,pch=95,col="darkmagenta")
axis(1,seq(1:5),c("Unitat 1", "Unitat 2", "Unitat SM", "Unitat
Mèdica", "Unitat Quirúrgica"))
axis(2,seq(-0.1,.1,.02))
for (i in 1:5){
  lines(c(i,i),c(ic.inf[i],ic.sup[i]),col="darkmagenta")
}
box()
box("outer",lwd=10,col="lightgoldenrod4")

efecte.u1 =
inla.rmarginal(1000,resultat1$marginals.random$unidad2[names(resultat1
$marginals.random$unidad2)[1]][[1]])
efecte.u2 =
inla.rmarginal(1000,resultat1$marginals.random$unidad2[names(resultat1
$marginals.random$unidad2)[2]][[1]])
efecte.u3 =
inla.rmarginal(1000,resultat1$marginals.random$unidad2[names(resultat1
$marginals.random$unidad2)[3]][[1]])
efecte.u4 =
inla.rmarginal(1000,resultat1$marginals.random$unidad2[names(resultat1
$marginals.random$unidad2)[4]][[1]])
efecte.u5 =
inla.rmarginal(1000,resultat1$marginals.random$unidad2[names(resultat1
$marginals.random$unidad2)[5]][[1]])

mitjana<-
c(mean(efecte.u1),mean(efecte.u2),mean(efecte.u3),mean(efecte.u4),mean
(efecte.u5))

```

```

ic.inf<-
c(quantile(efecte.u1,0.025),quantile(efecte.u2,0.025),quantile(efecte.
u3,0.025),quantile(efecte.u4,0.025),quantile(efecte.u5,0.025))

ic.sup<-
c(quantile(efecte.u1,0.975),quantile(efecte.u2,0.975),quantile(efecte.
u3,0.975),quantile(efecte.u4,0.975),quantile(efecte.u5,0.975))

plot(1:5,mitjana,ylim=c(min(ic.inf),max(ic.sup)),xlim=c(0.95,5.05),col
="darkmagenta",pch=19,main="Mesurs associades a l'efecte de les
unitats en la taxa de caigudes",xlab="Unitats",ylab="",axes=F)
abline(h=0,col="darkolivegreen")
points(1:5,ic.inf,pch=95,col="darkmagenta")
points(1:5,ic.sup,pch=95,col="darkmagenta")
axis(1,seq(1:5),c("Unitat 1", "Unitat 2", "Unitat SM", "Unitat
Mèdica", "Unitat Quirúrgica"))
axis(2,seq(-0.1,.1,.02))
for (i in 1:5){
  lines(c(i,i),c(ic.inf[i],ic.sup[i]),col="darkmagenta")
}
box()
box("outer",lwd=10,col="lightgoldenrod4")

efecte.u1 =
inla.rmarginal(1000,resultat1$marginals.random$unidad3[names(resultat1
$marginals.random$unidad3)[1]][[1]])
efecte.u2 =
inla.rmarginal(1000,resultat1$marginals.random$unidad3[names(resultat1
$marginals.random$unidad3)[2]][[1]])
efecte.u3 =
inla.rmarginal(1000,resultat1$marginals.random$unidad3[names(resultat1
$marginals.random$unidad3)[3]][[1]])
efecte.u4 =
inla.rmarginal(1000,resultat1$marginals.random$unidad3[names(resultat1
$marginals.random$unidad3)[4]][[1]])
efecte.u5 =
inla.rmarginal(1000,resultat1$marginals.random$unidad3[names(resultat1
$marginals.random$unidad3)[5]][[1]])

mitjana<-
c(mean(efecte.u1),mean(efecte.u2),mean(efecte.u3),mean(efecte.u4),mean
(efecte.u5))

ic.inf<-
c(quantile(efecte.u1,0.025),quantile(efecte.u2,0.025),quantile(efecte.
u3,0.025),quantile(efecte.u4,0.025),quantile(efecte.u5,0.025))

ic.sup<-
c(quantile(efecte.u1,0.975),quantile(efecte.u2,0.975),quantile(efecte.
u3,0.975),quantile(efecte.u4,0.975),quantile(efecte.u5,0.975))

plot(1:5,mitjana,ylim=c(min(ic.inf),max(ic.sup)),xlim=c(0.95,5.05),col
="darkmagenta",pch=19,main="Temps associat a l'efecte de les unitats
en la taxa de caigudes",xlab="Unitats",ylab="",axes=F)
abline(h=0,col="darkolivegreen")

```

```

points(1:5,ic.inf,pch=95,col="darkmagenta")
points(1:5,ic.sup,pch=95,col="darkmagenta")
axis(1,seq(1:5),c("Unitat 1", "Unitat 2", "Unitat SM", "Unitat
Mèdica", "Unitat Quirúrgica"))
axis(2,seq(-0.1,.1,.02))
for (i in 1:5){
  lines(c(i,i),c(ic.inf[i],ic.sup[i]),col="darkmagenta")
}
box()
box("outer",lwd=10,col="lightgoldenrod4")

## Model 4: Efectes mixtes. Unitat dins d'hospital

unitat.hospital<-hospital*as.numeric(unidad)

Datos<-data.frame(Datos,unitat.hospital)

formula = obs~
f(hospital,model="iid")+f(unitat.hospital,model="iid")+explicativa+tem
ps+programa+tipus+outlier
resultat1 = inla(formula, family="poisson", control.compute =
list(dic=T,cpo=F),control.predictor=list(compute=T,cdf=c(log(1))),E=es
p, data=Datos,verbose=T)

formula = obs~
f(hospital,model="iid")+f(unitat.hospital,model="iid")+explicativa+tem
ps+tipus+any+valoracio+difusio+outlier
resultat1 = inla(formula, family="poisson", control.compute =
list(dic=T,cpo=F),control.predictor=list(compute=T,cdf=c(log(1))),E=es
p, data=Datos,verbose=T)

summary(resultat1)

resultat1$dic$dic

par(mfrow=c(1,3),oma=c(8,1,8,1))
#plot(resultat1$marginals.fixed$"explicativa"[,1],resultat1$marginals.
fixed$"explicativa"[,2],xlab="",ylab="",main="Efecte
Mesures",pch=19,col="darkgreen")
#abline(v=0,col="red")
#plot(resultat1$marginals.fixed$"temps"[,1],resultat1$marginals.fixed$
"temps"[,2],xlab="",ylab="",main="Efecte
Temps",pch=19,col="darkgreen")
#abline(v=0,col="red")
#plot(resultat1$marginals.fixed$"programa"[,1],resultat1$marginals.fix
ed$"programa"[,2],xlab="",ylab="",main="Efecte Programa
prevenció",pch=19,col="darkred")
#abline(v=0,col="red")
plot(resultat1$marginals.fixed$"any"[,1],resultat1$marginals.fixed$"an
y"[,2],xlab="",ylab="",main="Efecte Any
d' Implantació",pch=19,col="darkred")
abline(v=0,col="red")

```

```

plot(resultat1$marginals.fixed$"valoracio"[,1],resultat1$marginals.fixed$"valoracio"[,2],xlab="",ylab="",main="Efecte Valoració Risc Caiguda",pch=19,col="darkgreen")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"difusio"[,1],resultat1$marginals.fixed$"difusio"[,2],xlab="",ylab="",main="Efecte Difusió Resultats",pch=19,col="darkred")
abline(v=0,col="red")
#plot(resultat1$marginals.fixed$"tipus"[,1],resultat1$marginals.fixed$"tipus"[,2],xlab="",ylab="",main="Efecte Hospital vs CSS",pch=19,col="darkgreen")
#abline(v=0,col="red")
box("outer",lwd=10,col="lightgoldenrod4")

```

```

efecte.h1 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat1$marginals.random$hospital)[1]][[1]])
efecte.h2 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat1$marginals.random$hospital)[2]][[1]])
efecte.h3 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat1$marginals.random$hospital)[3]][[1]])
efecte.h4 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat1$marginals.random$hospital)[4]][[1]])
efecte.h5 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat1$marginals.random$hospital)[5]][[1]])
efecte.h6 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat1$marginals.random$hospital)[6]][[1]])
efecte.h7 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat1$marginals.random$hospital)[7]][[1]])
efecte.h8 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat1$marginals.random$hospital)[8]][[1]])
efecte.h9 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat1$marginals.random$hospital)[9]][[1]])
efecte.h10 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat1$marginals.random$hospital)[10]][[1]])
efecte.h11 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat1$marginals.random$hospital)[11]][[1]])
efecte.h12 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat1$marginals.random$hospital)[12]][[1]])
efecte.h13 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat1$marginals.random$hospital)[13]][[1]])
efecte.h14 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat1$marginals.random$hospital)[14]][[1]])
efecte.h15 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat1$marginals.random$hospital)[15]][[1]])

```



[illegible]

```

efecte.h36 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[36]][[1]])
efecte.h37 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[37]][[1]])
efecte.h38 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[38]][[1]])
efecte.h39 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[39]][[1]])
efecte.h40 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[40]][[1]])
efecte.h41 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[41]][[1]])
efecte.h42 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[42]][[1]])
efecte.h43 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[43]][[1]])
efecte.h44 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[44]][[1]])

```

```

mitjana<-
c(mean(efecte.h1),mean(efecte.h2),mean(efecte.h3),mean(efecte.h4),mean
(efecte.h5),mean(efecte.h6),mean(efecte.h7),mean(efecte.h8),
mean(efecte.h9),mean(efecte.h10),mean(efecte.h11),mean(efecte.h12),mea
n(efecte.h13),mean(efecte.h14),mean(efecte.h15),mean(efecte.h16),
mean(efecte.h17),mean(efecte.h18),mean(efecte.h19),mean(efecte.h20),me
an(efecte.h21),mean(efecte.h22),mean(efecte.h23),mean(efecte.h24),mean
(efecte.h25),
mean(efecte.h26),mean(efecte.h27),mean(efecte.h28),mean(efecte.h29),me
an(efecte.h30),mean(efecte.h31),mean(efecte.h32),mean(efecte.h33),mean
(efecte.h34),
mean(efecte.h35),mean(efecte.h36),mean(efecte.h37),mean(efecte.h38),me
an(efecte.h39),mean(efecte.h40),mean(efecte.h41),mean(efecte.h42),mean
(efecte.h43),
mean(efecte.h44))

```

```

ic.inf<-
c(quantile(efecte.h1,0.025),quantile(efecte.h2,0.025),quantile(efecte.
h3,0.025),quantile(efecte.h4,0.025),quantile(efecte.h5,0.025),quantile
(efecte.h6,0.025),quantile(efecte.h7,0.025),quantile(efecte.h8,0.025),
quantile(efecte.h9,0.025),quantile(efecte.h10,0.025),quantile(efecte.h
11,0.025),quantile(efecte.h12,0.025),quantile(efecte.h13,0.025),quanti
le(efecte.h14,0.025),quantile(efecte.h15,0.025),quantile(efecte.h16,0.
025),
quantile(efecte.h17,0.025),quantile(efecte.h18,0.025),quantile(efecte.
h19,0.025),quantile(efecte.h20,0.025),quantile(efecte.h21,0.025),quant
ile(efecte.h22,0.025),quantile(efecte.h23,0.025),quantile(efecte.h24,0
.025),quantile(efecte.h25,0.025),
quantile(efecte.h26,0.025),quantile(efecte.h27,0.025),quantile(efecte.
h28,0.025),quantile(efecte.h29,0.025),quantile(efecte.h30,0.025),quant
ile(efecte.h31,0.025),quantile(efecte.h32,0.025),quantile(efecte.h33,0
.025),quantile(efecte.h34,0.025),

```

```

quantile(efecte.h35,0.025),quantile(efecte.h36,0.025),quantile(efecte.
h37,0.025),quantile(efecte.h38,0.025),quantile(efecte.h39,0.025),quant
ile(efecte.h40,0.025),quantile(efecte.h41,0.025),quantile(efecte.h42,0
.025),quantile(efecte.h43,0.025),
quantile(efecte.h44,0.025))

ic.sup<-
c(quantile(efecte.h1,0.975),quantile(efecte.h2,0.975),quantile(efecte.
h3,0.975),quantile(efecte.h4,0.975),quantile(efecte.h5,0.975),quantile
(efecte.h6,0.975),quantile(efecte.h7,0.975),quantile(efecte.h8,0.975),
quantile(efecte.h9,0.975),quantile(efecte.h10,0.975),quantile(efecte.h
11,0.975),quantile(efecte.h12,0.975),quantile(efecte.h13,0.975),quanti
le(efecte.h14,0.975),quantile(efecte.h15,0.975),quantile(efecte.h16,0.
975),
quantile(efecte.h17,0.975),quantile(efecte.h18,0.975),quantile(efecte.
h19,0.975),quantile(efecte.h20,0.975),quantile(efecte.h21,0.975),quant
ile(efecte.h22,0.975),quantile(efecte.h23,0.975),quantile(efecte.h24,0
.975),quantile(efecte.h25,0.975),
quantile(efecte.h26,0.975),quantile(efecte.h27,0.975),quantile(efecte.
h28,0.975),quantile(efecte.h29,0.975),quantile(efecte.h30,0.975),quant
ile(efecte.h31,0.975),quantile(efecte.h32,0.975),quantile(efecte.h33,0
.975),quantile(efecte.h34,0.975),
quantile(efecte.h35,0.975),quantile(efecte.h36,0.975),quantile(efecte.
h37,0.975),quantile(efecte.h38,0.975),quantile(efecte.h39,0.975),quant
ile(efecte.h40,0.975),quantile(efecte.h41,0.975),quantile(efecte.h42,0
.975),quantile(efecte.h43,0.975),
quantile(efecte.h44,0.975))

par(mfrow=c(3,1))
plot(1:44,mitjana,ylim=c(min(ic.inf),max(ic.sup)),col="darkgrey",xlim=
c(0.95,44.05),pch=19,main="Efecte dels
hospitals",xlab="Hospitals",ylab="")
points(1:44,ic.inf,pch=95,col="darkgrey")
points(1:44,ic.sup,pch=95,col="darkgrey")
#axis(1,seq(1:44),cex.axis=.5)
abline(h=0,col="red")
for (i in 1:44){
  lines(c(i,i),c(ic.inf[i],ic.sup[i]),col="darkgrey")
}
box("outer",lwd=10,col="lightgoldenrod4")

```

```
#####
```

```
explicativa<- Percent_mean*as.numeric(Quinzena)
#temps<- as.numeric(Quinzena)
#hospital<- IdHospital
#unidad<-as.factor(as.numeric(Unidad))
```

```
#outlier<-rep(NA,nrow(datos))
#outlier[which(Percent_mean<0.42)]<-1
#outlier[which(Percent_mean>0.42)]<-0
```

```
#Datos<-data.frame(hospital=hospital,unidad=unidad,
explicativa=explicativa,temps=temps,outlier)
```

```
obs<- NumCaidas_sum
esp<- NumPacientes_sum
programa<-x1.ProgramaPrevecio*as.numeric(Quinzena)
implantacio<-x2.Implantacio*as.numeric(Quinzena)
any<-rep(NA,nrow(datos))
any[which(x3.AnyImplantacio=="1990")]<-
1990*as.numeric(Quinzena[which(x3.AnyImplantacio=="1990")])
any[which(x3.AnyImplantacio=="1994")]<-
1994*as.numeric(Quinzena[which(x3.AnyImplantacio=="1994")])
any[which(x3.AnyImplantacio=="1996")]<-
1996*as.numeric(Quinzena[which(x3.AnyImplantacio=="1996")])
any[which(x3.AnyImplantacio=="1998")]<-
1998*as.numeric(Quinzena[which(x3.AnyImplantacio=="1998")])
any[which(x3.AnyImplantacio=="1999")]<-
1999*as.numeric(Quinzena[which(x3.AnyImplantacio=="1999")])
any[which(x3.AnyImplantacio=="2000")]<-
2000*as.numeric(Quinzena[which(x3.AnyImplantacio=="2000")])
any[which(x3.AnyImplantacio=="2001")]<-
2001*as.numeric(Quinzena[which(x3.AnyImplantacio=="2001")])
any[which(x3.AnyImplantacio=="2002")]<-
2002*as.numeric(Quinzena[which(x3.AnyImplantacio=="2002")])
any[which(x3.AnyImplantacio=="2003")]<-
2003*as.numeric(Quinzena[which(x3.AnyImplantacio=="2003")])
any[which(x3.AnyImplantacio=="2004")]<-
2004*as.numeric(Quinzena[which(x3.AnyImplantacio=="2004")])
any[which(x3.AnyImplantacio=="2005")]<-
2005*as.numeric(Quinzena[which(x3.AnyImplantacio=="2005")])
any[which(x3.AnyImplantacio=="2007")]<-
2007*as.numeric(Quinzena[which(x3.AnyImplantacio=="2007")])
valoracio<-x4.ValoracioRisc*as.numeric(Quinzena)
difusio<-x5.Difusio*as.numeric(Quinzena)
tipus<-(as.numeric(Tabla)-1)*as.numeric(Quinzena) ## 1 = hospitals; 0
= css
temps2<-temps
unidad2<-unidad
unidad3<-interaction(hospital,unidad)
unidad4<-unidad3
unidad2<-unidad
```

```

explicativa2<-explicativa
hospital2<-hospital

outlier<-rep(NA,nrow(datos))
outlier[which(tanpermil>20)]<-1
outlier[which(tanpermil<20)]<-0

#sabates<-Zapatos_median*as.numeric(Quinzena)
#llit<-CamaBaja_median*as.numeric(Quinzena)
#registre<-RegTransfer_median*as.numeric(Quinzena)
#habitacio<-CercaEnf_median*as.numeric(Quinzena)
#timbre<-Timbre_median*as.numeric(Quinzena)
#lavabo<-LavaboSenyal_median*as.numeric(Quinzena)
#terra<-DuchaAnti_median*as.numeric(Quinzena)
#pacientrisc<-PacienteRiesgo_median*as.numeric(Quinzena)
#info<-PacienteInfo_median*as.numeric(Quinzena)

#MPacient<-MesuresPacient*as.numeric(Quinzena)
#MProfessionals<-MesuresProfessionals*as.numeric(Quinzena)
#MOrganitzacio<-MesuresOrganitzacio*as.numeric(Quinzena)

Datos<-data.frame(hospital=hospital,unidad=unidad,obs,esp,
explicativa=explicativa,temps=temps,programa,implantacio,any,valoracio
,difusio,tipus,temps2,explicativa2,unidad2,unidad3,hospital2,outlier)

## Model 1: Taxa caigudes vs Percentatge de compliment. Efectes fixes
formula = obs~ explicativa+implantacio+difusio+tipus+temps2+outlier
resultat1 = inla(formula, family="poisson", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
), data=Datos,E=esp,verbose=T)

summary(resultat1)

resultat1$dic$dic
-mean(log(resultat1$cpo),na.rm=T)
-mean(log(resultat1$cpo[resultat1$cpo>0]),na.rm=T)

par(mfrow=c(3,2))
plot(resultat1$marginals.fixed$"explicativa"[,1],resultat1$marginals.f
ixed$"explicativa"[,2],xlab="",ylab="",main="Efecte Mesures")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"implantacio"[,1],resultat1$marginals.f
ixed$"implantacio"[,2],xlab="",ylab="",main="Efecte Implantació")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"difusio"[,1],resultat1$marginals.fixed
$"difusio"[,2],xlab="",ylab="",main="Efecte difusio")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"tipus"[,1],resultat1$marginals.fixed$
"tipus"[,2],xlab="",ylab="",main="Efecte tipus")
abline(v=0,col="red")

```

```
plot(resultat1$marginals.fixed$"temps2"[,1],resultat1$marginals.fixed$
"temps2"[,2],xlab="",ylab="",main="Efecte temps")
abline(v=0,col="red")
box("outer",lwd=5)
```

```
## Model 2: Taxa caigudes vs Percentatge de compliment. Efectes
mixtes. Hospital, unitat i temps independents.
formula = obs~
explicativa+programa+implantacio+outlier+f(as.factor(hospital),model="
iid")+f(unidad,model="iid")+f(temps,model="iid")
resultat1 = inla(formula, family="poisson", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
), data=Datos,E=esp,verbose=T)
```

```
summary(resultat1)
```

```
resultat1$dic$dic
-mean(log(resultat1$cpo),na.rm=T)
-mean(log(resultat1$cpo[resultat1$cpo>0]),na.rm=T)
```

```
par(mfrow=c(3,1))
plot(resultat1$marginals.fixed$"explicativa"[,1],resultat1$marginals.f
ixed$"explicativa"[,2],xlab="",ylab="",main="Efecte Mesures")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"programa"[,1],resultat1$marginals.fixe
d$"programa"[,2],xlab="",ylab="",main="Efecte Programa")
habline(v=0,col="red")
plot(resultat1$medianat1$marginals.fixed$"implantacio"[,1],resultat
1$marginals.fixed$"implantacio"[,2],xlab="",ylab="",main="Efecte
Implantació")
abline(v=0,col="red")
box("outer",lwd=5)
```

```
### Anem a veure quin és l'efecte de cada hospital.
```

```
resultat1$marginals.random
resultat1$marginals.random$hospital[names(resultat1$marginals.random$h
ospital)[i]] # La distribució marginal de l'hospital i per les mesures
```

```
# Generem una mostra aleatoria de l'efecte aleatori de les mesures per
cada hospital
```

```
efecte.h1 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[1]][[1]])
efecte.h2 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[2]][[1]])
efecte.h3 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[3]][[1]])
```

```

efecte.h4 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[4]][[1]])
efecte.h5 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[5]][[1]])
efecte.h6 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[6]][[1]])
efecte.h7 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[7]][[1]])
efecte.h8 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[8]][[1]])
efecte.h9 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[9]][[1]])
efecte.h10 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[10]][[1]])
efecte.h11 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[11]][[1]])
efecte.h12 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[12]][[1]])
efecte.h13 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[13]][[1]])
efecte.h14 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[14]][[1]])
efecte.h15 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[15]][[1]])
efecte.h16 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[16]][[1]])
efecte.h17 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[17]][[1]])
efecte.h18 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[18]][[1]])
efecte.h19 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[19]][[1]])
efecte.h20 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[20]][[1]])
efecte.h21 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[21]][[1]])
efecte.h22 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[22]][[1]])
efecte.h23 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[23]][[1]])

```





```
efecte.h44 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[44]][[1]])
```

```
mitjana<-
c(mean(efecte.h1),mean(efecte.h2),mean(efecte.h3),mean(efecte.h4),mean
(efecte.h5),mean(efecte.h6),mean(efecte.h7),mean(efecte.h8),
mean(efecte.h9),mean(efecte.h10),mean(efecte.h11),mean(efecte.h12),mea
n(efecte.h13),mean(efecte.h14),mean(efecte.h15),mean(efecte.h16),
mean(efecte.h17),mean(efecte.h18),mean(efecte.h19),mean(efecte.h20),me
an(efecte.h21),mean(efecte.h22),mean(efecte.h23),mean(efecte.h24),mean
(efecte.h25),
mean(efecte.h26),mean(efecte.h27),mean(efecte.h28),mean(efecte.h29),me
an(efecte.h30),mean(efecte.h31),mean(efecte.h32),mean(efecte.h33),mean
(efecte.h34),
mean(efecte.h35),mean(efecte.h36),mean(efecte.h37),mean(efecte.h38),me
an(efecte.h39),mean(efecte.h40),mean(efecte.h41),mean(efecte.h42),mean
(efecte.h43),
mean(efecte.h44))
```

```
ic.inf<-
c(quantile(efecte.h1,0.025),quantile(efecte.h2,0.025),quantile(efecte.
h3,0.025),quantile(efecte.h4,0.025),quantile(efecte.h5,0.025),quantile
(efecte.h6,0.025),quantile(efecte.h7,0.025),quantile(efecte.h8,0.025),
quantile(efecte.h9,0.025),quantile(efecte.h10,0.025),quantile(efecte.h
11,0.025),quantile(efecte.h12,0.025),quantile(efecte.h13,0.025),quanti
le(efecte.h14,0.025),quantile(efecte.h15,0.025),quantile(efecte.h16,0.
025),
quantile(efecte.h17,0.025),quantile(efecte.h18,0.025),quantile(efecte.
h19,0.025),quantile(efecte.h20,0.025),quantile(efecte.h21,0.025),quant
ile(efecte.h22,0.025),quantile(efecte.h23,0.025),quantile(efecte.h24,0
.025),quantile(efecte.h25,0.025),
quantile(efecte.h26,0.025),quantile(efecte.h27,0.025),quantile(efecte.
h28,0.025),quantile(efecte.h29,0.025),quantile(efecte.h30,0.025),quant
ile(efecte.h31,0.025),quantile(efecte.h32,0.025),quantile(efecte.h33,0
.025),quantile(efecte.h34,0.025),
quantile(efecte.h35,0.025),quantile(efecte.h36,0.025),quantile(efecte.
h37,0.025),quantile(efecte.h38,0.025),quantile(efecte.h39,0.025),quant
ile(efecte.h40,0.025),quantile(efecte.h41,0.025),quantile(efecte.h42,0
.025),quantile(efecte.h43,0.025),
quantile(efecte.h44,0.025))
```

```
ic.sup<-
c(quantile(efecte.h1,0.975),quantile(efecte.h2,0.975),quantile(efecte.
h3,0.975),quantile(efecte.h4,0.975),quantile(efecte.h5,0.975),quantile
(efecte.h6,0.975),quantile(efecte.h7,0.975),quantile(efecte.h8,0.975),
quantile(efecte.h9,0.975),quantile(efecte.h10,0.975),quantile(efecte.h
11,0.975),quantile(efecte.h12,0.975),quantile(efecte.h13,0.975),quanti
le(efecte.h14,0.975),quantile(efecte.h15,0.975),quantile(efecte.h16,0.
975),
quantile(efecte.h17,0.975),quantile(efecte.h18,0.975),quantile(efecte.
h19,0.975),quantile(efecte.h20,0.975),quantile(efecte.h21,0.975),quant
ile(efecte.h22,0.975),quantile(efecte.h23,0.975),quantile(efecte.h24,0
.975),quantile(efecte.h25,0.975),
quantile(efecte.h26,0.975),quantile(efecte.h27,0.975),quantile(efecte.
h28,0.975),quantile(efecte.h29,0.975),quantile(efecte.h30,0.975),quant
ile(efecte.h31,0.975),quantile(efecte.h32,0.975),quantile(efecte.h33,0
.975),quantile(efecte.h34,0.975),
quantile(efecte.h35,0.975),quantile(efecte.h36,0.975),quantile(efecte.
h37,0.975),quantile(efecte.h38,0.975),quantile(efecte.h39,0.975),quant
```

```

ile(efecte.h40,0.975),quantile(efecte.h41,0.975),quantile(efecte.h42,0
.975),quantile(efecte.h43,0.975),
quantile(efecte.h44,0.975))

par(mfrow=c(3,1))
plot(1:44,mitjana,ylim=c(min(ic.inf),max(ic.sup)),xlim=c(0.95,44.05),p
ch=19,main="Efecte dels hospitals",xlab="Hospitals",ylab="")
points(1:44,ic.inf,pch=95,col="blue")
points(1:44,ic.sup,pch=95,col="blue")
#axis(1,seq(1:44),cex.axis=.5)
abline(h=0,col="red")
for (i in 1:44){
  lines(c(i,i),c(ic.inf[i],ic.sup[i]),col="blue")
}
box("outer",lwd=10)

# Efecte unitats

efecte.u1 =
inla.rmarginal(1000,resultat1$marginals.random$unidad[names(resultat1$
marginals.random$unidad)[1]][[1]])
efecte.u2 =
inla.rmarginal(1000,resultat1$marginals.random$unidad[names(resultat1$
marginals.random$unidad)[2]][[1]])
efecte.u3 =
inla.rmarginal(1000,resultat1$marginals.random$unidad[names(resultat1$
marginals.random$unidad)[3]][[1]])
efecte.u4 =
inla.rmarginal(1000,resultat1$marginals.random$unidad[names(resultat1$
marginals.random$unidad)[4]][[1]])
efecte.u5 =
inla.rmarginal(1000,resultat1$marginals.random$unidad[names(resultat1$
marginals.random$unidad)[5]][[1]])

mitjana<-
c(mean(efecte.u1),mean(efecte.u2),mean(efecte.u3),mean(efecte.u4),mean
(efecte.u5))

ic.inf<-
c(quantile(efecte.u1,0.025),quantile(efecte.u2,0.025),quantile(efecte.
u3,0.025),quantile(efecte.u4,0.025),quantile(efecte.u5,0.025))

ic.sup<-
c(quantile(efecte.u1,0.975),quantile(efecte.u2,0.975),quantile(efecte.
u3,0.975),quantile(efecte.u4,0.975),quantile(efecte.u5,0.975))

plot(1:5,mitjana,ylim=c(min(ic.inf),max(ic.sup)),xlim=c(0.95,5.05),pch
=19,main="Efecte de les unitats",xlab="Unitats",ylab="")
points(1:5,ic.inf,pch=95,col="blue")
points(1:5,ic.sup,pch=95,col="blue")
axis(1,seq(1:5),c("Unitat 1", "Unitat 2", "Unitat SM", "Unitat
Mèdica", "Unitat Quirúrgica"))
abline(h=0,col="red")
for (i in 1:5){
  lines(c(i,i),c(ic.inf[i],ic.sup[i]),col="blue")
}

```

```
## Efecte quinzena
```

```
efecte.t1 =  
inla.rmarginal(1000,resultat1$marginals.random$temps[names(resultat1$m  
arginals.random$temps)[1]][[1]])  
efecte.t2 =  
inla.rmarginal(1000,resultat1$marginals.random$temps[names(resultat1$m  
arginals.random$temps)[2]][[1]])  
efecte.t3 =  
inla.rmarginal(1000,resultat1$marginals.random$temps[names(resultat1$m  
arginals.random$temps)[3]][[1]])  
efecte.t4 =  
inla.rmarginal(1000,resultat1$marginals.random$temps[names(resultat1$m  
arginals.random$temps)[4]][[1]])  
efecte.t5 =  
inla.rmarginal(1000,resultat1$marginals.random$temps[names(resultat1$m  
arginals.random$temps)[5]][[1]])  
efecte.t6 =  
inla.rmarginal(1000,resultat1$marginals.random$temps[names(resultat1$m  
arginals.random$temps)[6]][[1]])  
efecte.t7 =  
inla.rmarginal(1000,resultat1$marginals.random$temps[names(resultat1$m  
arginals.random$temps)[7]][[1]])  
efecte.t8 =  
inla.rmarginal(1000,resultat1$marginals.random$temps[names(resultat1$m  
arginals.random$temps)[8]][[1]])  
efecte.t9 =  
inla.rmarginal(1000,resultat1$marginals.random$temps[names(resultat1$m  
arginals.random$temps)[9]][[1]])  
efecte.t10 =  
inla.rmarginal(1000,resultat1$marginals.random$temps[names(resultat1$m  
arginals.random$temps)[10]][[1]])  
efecte.t11 =  
inla.rmarginal(1000,resultat1$marginals.random$temps[names(resultat1$m  
arginals.random$temps)[11]][[1]])  
efecte.t12 =  
inla.rmarginal(1000,resultat1$marginals.random$temps[names(resultat1$m  
arginals.random$temps)[12]][[1]])
```

```
mitjana<-  
c(mean(efecte.t1),mean(efecte.t2),mean(efecte.t3),mean(efecte.t4),mean  
(efecte.t5),mean(efecte.t6),mean(efecte.t7),mean(efecte.t8),  
mean(efecte.t9),mean(efecte.t10),mean(efecte.t11),mean(efecte.t12))
```

```
ic.inf<-  
c(quantile(efecte.t1,0.025),quantile(efecte.t2,0.025),quantile(efecte.  
t3,0.025),quantile(efecte.t4,0.025),quantile(efecte.t5,0.025),quantile  
(efecte.t6,0.025),quantile(efecte.t7,0.025),quantile(efecte.t8,0.025),  
quantile(efecte.t9,0.025),quantile(efecte.t10,0.025),quantile(efecte.t  
11,0.025),quantile(efecte.t12,0.025))
```

```
ic.sup<-  
c(quantile(efecte.t1,0.975),quantile(efecte.t2,0.975),quantile(efecte.  
t3,0.975),quantile(efecte.t4,0.975),quantile(efecte.t5,0.975),quantile  
(efecte.t6,0.975),quantile(efecte.t7,0.975),quantile(efecte.t8,0.975),  
quantile(efecte.t9,0.975),quantile(efecte.t10,0.975),quantile(efecte.t  
11,0.975),quantile(efecte.t12,0.975))
```

```

plot(1:12,mitjana,ylim=c(min(ic.inf),max(ic.sup)),xlim=c(0.95,12.05),pch=19,main="Efecte de les quinzenes",xlab="Quinzenes",ylab="")
points(1:12,ic.inf,pch=95,col="blue")
points(1:12,ic.sup,pch=95,col="blue")
axis(1,seq(1:12))
abline(h=0,col="red")
for (i in 1:12){
  lines(c(i,i),c(ic.inf[i],ic.sup[i]),col="blue")
}

```

## Té algun efecte aleatòri les mesures en els hospitals?

```

formula = obs~
f(hospital,model="iid")+f(hospital2,explicativa2,model="iid")+f(unidad
,model="iid")+f(temps2,model="iid")+
explicativa+programa+implantacio
resultat1 = inla(formula, family="poisson", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
), data=Datos,E=esp)

```

```
summary(resultat1)
```

```

resultat1$dic$dic
-mean(log(resultat1$cpo),na.rm=T)
-mean(log(resultat1$cpo[resultat1$cpo>0]),na.rm=T)

```

```

par(mfrow=c(2,2))
plot(resultat1$marginals.fixed$"explicativa"[,1],resultat1$marginals.f
ixed$"explicativa"[,2],xlab="",ylab="",main="Efecte Mesures")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"programa"[,1],resultat1$marginals.fixe
d$"programa"[,2],xlab="",ylab="",main="Efecte Programa")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"implantacio"[,1],resultat1$marginals.f
ixed$"implantacio"[,2],xlab="",ylab="",main="Efecte Implantació")
abline(v=0,col="red")
box("outer",lwd=5)

```

```

# Generem una mostra aleatoria de l'efecte aleatori de les mesures per
cada hospital
efecte.h1 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[1]][[1]])
efecte.h2 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[2]][[1]])
efecte.h3 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[3]][[1]])

```

```

efecte.h4 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[4]][[1]])
efecte.h5 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[5]][[1]])
efecte.h6 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[6]][[1]])
efecte.h7 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[7]][[1]])
efecte.h8 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[8]][[1]])
efecte.h9 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[9]][[1]])
efecte.h10 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[10]][[1]])
efecte.h11 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[11]][[1]])
efecte.h12 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[12]][[1]])
efecte.h13 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[13]][[1]])
efecte.h14 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[14]][[1]])
efecte.h15 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[15]][[1]])
efecte.h16 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[16]][[1]])
efecte.h17 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[17]][[1]])
efecte.h18 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[18]][[1]])
efecte.h19 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[19]][[1]])
efecte.h20 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[20]][[1]])
efecte.h21 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[21]][[1]])
efecte.h22 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[22]][[1]])
efecte.h23 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[23]][[1]])

```



```

efecte.h44 =
inla.rmarginal(1000,resultat1$marginals.random$hospital2[names(resulta
t1$marginals.random$hospital2)[44]][[1]])

mitjana<-
c(mean(efecte.h1),mean(efecte.h2),mean(efecte.h3),mean(efecte.h4),mean
(efecte.h5),mean(efecte.h6),mean(efecte.h7),mean(efecte.h8),
mean(efecte.h9),mean(efecte.h10),mean(efecte.h11),mean(efecte.h12),mea
n(efecte.h13),mean(efecte.h14),mean(efecte.h15),mean(efecte.h16),
mean(efecte.h17),mean(efecte.h18),mean(efecte.h19),mean(efecte.h20),me
an(efecte.h21),mean(efecte.h22),mean(efecte.h23),mean(efecte.h24),mean
(efecte.h25),
mean(efecte.h26),mean(efecte.h27),mean(efecte.h28),mean(efecte.h29),me
an(efecte.h30),mean(efecte.h31),mean(efecte.h32),mean(efecte.h33),mean
(efecte.h34),
mean(efecte.h35),mean(efecte.h36),mean(efecte.h37),mean(efecte.h38),me
an(efecte.h39),mean(efecte.h40),mean(efecte.h41),mean(efecte.h42),mean
(efecte.h43),
mean(efecte.h44))

ic.inf<-
c(quantile(efecte.h1,0.025),quantile(efecte.h2,0.025),quantile(efecte.
h3,0.025),quantile(efecte.h4,0.025),quantile(efecte.h5,0.025),quantile
(efecte.h6,0.025),quantile(efecte.h7,0.025),quantile(efecte.h8,0.025),
quantile(efecte.h9,0.025),quantile(efecte.h10,0.025),quantile(efecte.h
11,0.025),quantile(efecte.h12,0.025),quantile(efecte.h13,0.025),quanti
le(efecte.h14,0.025),quantile(efecte.h15,0.025),quantile(efecte.h16,0.
025),
quantile(efecte.h17,0.025),quantile(efecte.h18,0.025),quantile(efecte.
h19,0.025),quantile(efecte.h20,0.025),quantile(efecte.h21,0.025),quant
ile(efecte.h22,0.025),quantile(efecte.h23,0.025),quantile(efecte.h24,0
.025),quantile(efecte.h25,0.025),
quantile(efecte.h26,0.025),quantile(efecte.h27,0.025),quantile(efecte.
h28,0.025),quantile(efecte.h29,0.025),quantile(efecte.h30,0.025),quant
ile(efecte.h31,0.025),quantile(efecte.h32,0.025),quantile(efecte.h33,0
.025),quantile(efecte.h34,0.025),
quantile(efecte.h35,0.025),quantile(efecte.h36,0.025),quantile(efecte.
h37,0.025),quantile(efecte.h38,0.025),quantile(efecte.h39,0.025),quant
ile(efecte.h40,0.025),quantile(efecte.h41,0.025),quantile(efecte.h42,0
.025),quantile(efecte.h43,0.025),
quantile(efecte.h44,0.025))

ic.sup<-
c(quantile(efecte.h1,0.975),quantile(efecte.h2,0.975),quantile(efecte.
h3,0.975),quantile(efecte.h4,0.975),quantile(efecte.h5,0.975),quantile
(efecte.h6,0.975),quantile(efecte.h7,0.975),quantile(efecte.h8,0.975),
quantile(efecte.h9,0.975),quantile(efecte.h10,0.975),quantile(efecte.h
11,0.975),quantile(efecte.h12,0.975),quantile(efecte.h13,0.975),quanti
le(efecte.h14,0.975),quantile(efecte.h15,0.975),quantile(efecte.h16,0.
975),
quantile(efecte.h17,0.975),quantile(efecte.h18,0.975),quantile(efecte.
h19,0.975),quantile(efecte.h20,0.975),quantile(efecte.h21,0.975),quant
ile(efecte.h22,0.975),quantile(efecte.h23,0.975),quantile(efecte.h24,0
.975),quantile(efecte.h25,0.975),
quantile(efecte.h26,0.975),quantile(efecte.h27,0.975),quantile(efecte.
h28,0.975),quantile(efecte.h29,0.975),quantile(efecte.h30,0.975),quant
ile(efecte.h31,0.975),quantile(efecte.h32,0.975),quantile(efecte.h33,0
.975),quantile(efecte.h34,0.975),
quantile(efecte.h35,0.975),quantile(efecte.h36,0.975),quantile(efecte.
h37,0.975),quantile(efecte.h38,0.975),quantile(efecte.h39,0.975),quant

```

```

ile(efecte.h40,0.975),quantile(efecte.h41,0.975),quantile(efecte.h42,0
.975),quantile(efecte.h43,0.975),
quantile(efecte.h44,0.975))

plot(1:44,mitjana,ylim=c(min(ic.inf),max(ic.sup)),xlim=c(0.95,44.05),p
ch=19,main="Efecte de les mesures per cada
hospital",xlab="Hospitals",ylab="")
points(1:44,ic.inf,pch=95,col="blue")
points(1:44,ic.sup,pch=95,col="blue")
#axis(1,seq(1:44),cex.axis=.5)
abline(h=0,col="red")
for (i in 1:44){
  lines(c(i,i),c(ic.inf[i],ic.sup[i]),col="blue")
}
box("outer",lwd=10)

## Té algun efecte aleatòri les mesures en les unitats?

formula = obs~
f(hospital,model="iid")+f(unidad,model="iid")+f(unidad2,explicativa2,m
odel="iid")+f(temps2,model="iid")+
explicativa+programa+implantacio
resultat1 = inla(formula, family="poisson", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
), data=Datos,E=esp)

summary(resultat1)

resultat1$dic$dic
-mean(log(resultat1$cpo),na.rm=T)
-mean(log(resultat1$cpo[resultat1$cpo>0]),na.rm=T)

par(mfrow=c(2,2))
plot(resultat1$marginals.fixed$"explicativa"[,1],resultat1$marginals.f
ixed$"explicativa"[,2],xlab="",ylab="",main="Efecte Mesures")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"programa"[,1],resultat1$marginals.fixe
d$"programa"[,2],xlab="",ylab="",main="Efecte Programa")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"implantacio"[,1],resultat1$marginals.f
ixed$"implantacio"[,2],xlab="",ylab="",main="Efecte Implantació")
abline(v=0,col="red")
box("outer",lwd=5)

efecte.u1 =
inla.rmarginal(1000,resultat1$marginals.random$unidad2[names(resultat1
$marginals.random$unidad2)[1]][[1]])
efecte.u2 =
inla.rmarginal(1000,resultat1$marginals.random$unidad2[names(resultat1
$marginals.random$unidad2)[2]][[1]])
efecte.u3 =
inla.rmarginal(1000,resultat1$marginals.random$unidad2[names(resultat1
$marginals.random$unidad2)[3]][[1]])

```



```

efecte.u4 =
inla.rmarginal(1000,resultat1$marginals.random$unidad2[names(resultat1
$marginals.random$unidad2)[4]][[1]])
efecte.u5 =
inla.rmarginal(1000,resultat1$marginals.random$unidad2[names(resultat1
$marginals.random$unidad2)[5]][[1]])

mitjana<-
c(mean(efecte.u1),mean(efecte.u2),mean(efecte.u3),mean(efecte.u4),mean
(efecte.u5))

ic.inf<-
c(quantile(efecte.u1,0.025),quantile(efecte.u2,0.025),quantile(efecte.
u3,0.025),quantile(efecte.u4,0.025),quantile(efecte.u5,0.025))

ic.sup<-
c(quantile(efecte.u1,0.975),quantile(efecte.u2,0.975),quantile(efecte.
u3,0.975),quantile(efecte.u4,0.975),quantile(efecte.u5,0.975))

plot(1:5,mitjana,ylim=c(min(ic.inf),max(ic.sup)),xlim=c(0.95,5.05),pch
=19,main="Efecte de les mesures en les
unitats",xlab="Unitats",ylab="")
points(1:5,ic.inf,pch=95,col="blue")
points(1:5,ic.sup,pch=95,col="blue")
axis(1,seq(1:5),c("Unitat 1", "Unitat 2", "Unitat SM", "Unitat
Mèdica", "Unitat Quirúrgica"))
abline(h=0,col="red")
for (i in 1:5){
  lines(c(i,i),c(ic.inf[i],ic.sup[i]),col="blue")
}

## Model 3: Taxa caigudes vs Percentatge de compliment. Efectes
mixtes. Unitat dins d'hospital.
formula = obs~ f(hospital,model="iid")+f(unidad3,model="iid")+
explicativa+implantacio+temps+outlier
resultat1 = inla(formula, family="poisson", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
), data=Datos,E=esp)

summary(resultat1)

resultat1$dic$dic
-mean(log(resultat1$cpo),na.rm=T)
-mean(log(resultat1$cpo[resultat1$cpo>0]),na.rm=T)

par(mfrow=c(3,1))
plot(resultat1$marginals.fixed$"explicativa"[,1],resultat1$marginals.f
ixed$"explicativa"[,2],xlab="",ylab="",main="Efecte Mesures")
abline(v=0,col="red")

```

```

plot(resultat1$marginals.fixed$"temps"[,1],resultat1$marginals.fixed$"
temps"[,2],xlab="",ylab="",main="Efecte Quinzena")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"implantacio"[,1],resultat1$marginals.f
ixed$"implantacio"[,2],xlab="",ylab="",main="Efecte Implantació")
abline(v=0,col="red")
box("outer",lwd=5)

```

### Anem a veure quin és l'efecte de cada hospital.

```

resultat1$marginals.random
resultat1$marginals.random$hospital[names(resultat1$marginals.random$h
ospital)[i]] # La distribució marginal de l'hospital i per les mesures

```

# Generem una mostra aleatoria de l'efecte aleatori de les mesures per cada hospital

```

efecte.h1 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[1]][[1]])
efecte.h2 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[2]][[1]])
efecte.h3 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[3]][[1]])
efecte.h4 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[4]][[1]])
efecte.h5 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[5]][[1]])
efecte.h6 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[6]][[1]])
efecte.h7 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[7]][[1]])
efecte.h8 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[8]][[1]])
efecte.h9 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[9]][[1]])
efecte.h10 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[10]][[1]])
efecte.h11 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[11]][[1]])
efecte.h12 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[12]][[1]])
efecte.h13 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[13]][[1]])
efecte.h14 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[14]][[1]])

```



```

efecte.h35 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[35]][[1]])
efecte.h36 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[36]][[1]])
efecte.h37 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[37]][[1]])
efecte.h38 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[38]][[1]])
efecte.h39 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[39]][[1]])
efecte.h40 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[40]][[1]])
efecte.h41 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[41]][[1]])
efecte.h42 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[42]][[1]])
efecte.h43 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[43]][[1]])
efecte.h44 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[44]][[1]])

```

```

mitjana<-
c(mean(efecte.h1),mean(efecte.h2),mean(efecte.h3),mean(efecte.h4),mean
(efecte.h5),mean(efecte.h6),mean(efecte.h7),mean(efecte.h8),
mean(efecte.h9),mean(efecte.h10),mean(efecte.h11),mean(efecte.h12),mea
n(efecte.h13),mean(efecte.h14),mean(efecte.h15),mean(efecte.h16),
mean(efecte.h17),mean(efecte.h18),mean(efecte.h19),mean(efecte.h20),mea
n(efecte.h21),mean(efecte.h22),mean(efecte.h23),mean(efecte.h24),mean
(efecte.h25),
mean(efecte.h26),mean(efecte.h27),mean(efecte.h28),mean(efecte.h29),mea
n(efecte.h30),mean(efecte.h31),mean(efecte.h32),mean(efecte.h33),mean
(efecte.h34),
mean(efecte.h35),mean(efecte.h36),mean(efecte.h37),mean(efecte.h38),mea
n(efecte.h39),mean(efecte.h40),mean(efecte.h41),mean(efecte.h42),mean
(efecte.h43),
mean(efecte.h44))

```

```

ic.inf<-
c(quantile(efecte.h1,0.025),quantile(efecte.h2,0.025),quantile(efecte.
h3,0.025),quantile(efecte.h4,0.025),quantile(efecte.h5,0.025),quantile
(efecte.h6,0.025),quantile(efecte.h7,0.025),quantile(efecte.h8,0.025),
quantile(efecte.h9,0.025),quantile(efecte.h10,0.025),quantile(efecte.h
11,0.025),quantile(efecte.h12,0.025),quantile(efecte.h13,0.025),quanti
le(efecte.h14,0.025),quantile(efecte.h15,0.025),quantile(efecte.h16,0.
025),
quantile(efecte.h17,0.025),quantile(efecte.h18,0.025),quantile(efecte.
h19,0.025),quantile(efecte.h20,0.025),quantile(efecte.h21,0.025),quant
ile(efecte.h22,0.025),quantile(efecte.h23,0.025),quantile(efecte.h24,0
.025),quantile(efecte.h25,0.025),

```

```

quantile(efecte.h26,0.025),quantile(efecte.h27,0.025),quantile(efecte.
h28,0.025),quantile(efecte.h29,0.025),quantile(efecte.h30,0.025),quant
ile(efecte.h31,0.025),quantile(efecte.h32,0.025),quantile(efecte.h33,0
.025),quantile(efecte.h34,0.025),
quantile(efecte.h35,0.025),quantile(efecte.h36,0.025),quantile(efecte.
h37,0.025),quantile(efecte.h38,0.025),quantile(efecte.h39,0.025),quant
ile(efecte.h40,0.025),quantile(efecte.h41,0.025),quantile(efecte.h42,0
.025),quantile(efecte.h43,0.025),
quantile(efecte.h44,0.025))

ic.sup<-
c(quantile(efecte.h1,0.975),quantile(efecte.h2,0.975),quantile(efecte.
h3,0.975),quantile(efecte.h4,0.975),quantile(efecte.h5,0.975),quantile
(efecte.h6,0.975),quantile(efecte.h7,0.975),quantile(efecte.h8,0.975),
quantile(efecte.h9,0.975),quantile(efecte.h10,0.975),quantile(efecte.h
11,0.975),quantile(efecte.h12,0.975),quantile(efecte.h13,0.975),quanti
le(efecte.h14,0.975),quantile(efecte.h15,0.975),quantile(efecte.h16,0.
975),
quantile(efecte.h17,0.975),quantile(efecte.h18,0.975),quantile(efecte.
h19,0.975),quantile(efecte.h20,0.975),quantile(efecte.h21,0.975),quant
ile(efecte.h22,0.975),quantile(efecte.h23,0.975),quantile(efecte.h24,0
.975),quantile(efecte.h25,0.975),
quantile(efecte.h26,0.975),quantile(efecte.h27,0.975),quantile(efecte.
h28,0.975),quantile(efecte.h29,0.975),quantile(efecte.h30,0.975),quant
ile(efecte.h31,0.975),quantile(efecte.h32,0.975),quantile(efecte.h33,0
.975),quantile(efecte.h34,0.975),
quantile(efecte.h35,0.975),quantile(efecte.h36,0.975),quantile(efecte.
h37,0.975),quantile(efecte.h38,0.975),quantile(efecte.h39,0.975),quant
ile(efecte.h40,0.975),quantile(efecte.h41,0.975),quantile(efecte.h42,0
.975),quantile(efecte.h43,0.975),
quantile(efecte.h44,0.975))

#par(mfrow=c(2,1))
plot(1:44,mitjana,ylim=c(min(ic.inf),max(ic.sup)),xlim=c(0.95,44.05),p
ch=19,main="Efecte dels hospitals",xlab="Hospitals",ylab="")
points(1:44,ic.inf,pch=95,col="blue")
points(1:44,ic.sup,pch=95,col="blue")
#axis(1,seq(1:44),cex.axis=.5)
abline(h=0,col="red")
for (i in 1:44){
  lines(c(i,i),c(ic.inf[i],ic.sup[i]),col="blue")
}
box("outer",lwd=10)

## Té algun efecte aleatòri les mesures en els hospitals?
formula = obs~
f(hospital,model="iid")+f(unidad3,model="iid")+f(unidad4,explicativa2,
model="iid")+
explicativa+implantacio+temps+outlier
resultat1 = inla(formula, family="poisson", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
), data=Datos,E=esp)

summary(resultat1)

resultat1$dic$dic
-mean(log(resultat1$cpo),na.rm=T)
-mean(log(resultat1$cpo[resultat1$cpo>0]),na.rm=T)

```

```
##### VALIDACIÓ DEL MODEL
```

```
# Taxes de caigudes
```

```
RR<-resultat1$summary.fitted.values$mean*1000
```

```
res<-abs(tanpermil-RR)
```

```
res.ok<-rep(NA,length(res))
```

```
res.ok[which(abs(res)<2)]<-1
```

```
res.ok[which(abs(res)>2)]<-0
```

```
par(mfrow=c(1,2))
```

```
boxplot(res,main="Taxa de caigudes estimada")
```

```
boxplot(tanpermil,main="Taxa de caigudes observada")
```

```
box("outer",lwd=10)
```

```
## Model 4: Taxa caigudes vs Percentatge de compliment. Efectes  
mixtes. Hospital dins d'unitat.
```

```

formula = obs~ f(unidad,model="iid")+f(unidad3,model="iid")+
explicativa+temps+implantacio
resultat1 = inla(formula, family="poisson", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
), data=Datos,E=esp)

summary(resultat1)

resultat1$dic$dic
-mean(log(resultat1$cpo),na.rm=T)
-mean(log(resultat1$cpo[resultat1$cpo>0]),na.rm=T)

par(mfrow=c(3,1))
plot(resultat1$marginals.fixed$"explicativa"[,1],resultat1$marginals.f
ixed$"explicativa"[,2],xlab="",ylab="",main="Efecte Mesures")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"implantacio"[,1],resultat1$marginals.f
ixed$"implantacio"[,2],xlab="",ylab="",main="Efecte Implantació")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"temps"[,1],resultat1$marginals.fixed$"
temps"[,2],xlab="",ylab="",main="Efecte Quinzena")
abline(v=0,col="red")
box("outer",lwd=5)

# Efecte unitats

efecte.u1 =
inla.rmarginal(1000,resultat1$marginals.random$unidad[names(resultat1$
marginals.random$unidad)[1]][[1]])
efecte.u2 =
inla.rmarginal(1000,resultat1$marginals.random$unidad[names(resultat1$
marginals.random$unidad)[2]][[1]])
efecte.u3 =
inla.rmarginal(1000,resultat1$marginals.random$unidad[names(resultat1$
marginals.random$unidad)[3]][[1]])
efecte.u4 =
inla.rmarginal(1000,resultat1$marginals.random$unidad[names(resultat1$
marginals.random$unidad)[4]][[1]])
efecte.u5 =
inla.rmarginal(1000,resultat1$marginals.random$unidad[names(resultat1$
marginals.random$unidad)[5]][[1]])

mitjana<-
c(mean(efecte.u1),mean(efecte.u2),mean(efecte.u3),mean(efecte.u4),mean
(efecte.u5))

ic.inf<-
c(quantile(efecte.u1,0.025),quantile(efecte.u2,0.025),quantile(efecte.
u3,0.025),quantile(efecte.u4,0.025),quantile(efecte.u5,0.025))

ic.sup<-
c(quantile(efecte.u1,0.975),quantile(efecte.u2,0.975),quantile(efecte.
u3,0.975),quantile(efecte.u4,0.975),quantile(efecte.u5,0.975))

```

```

plot(1:5,mitjana,ylim=c(min(ic.inf),max(ic.sup)),xlim=c(0.95,5.05),pch
=19,main="Efecte de les unitats",xlab="Unitats",ylab="")
points(1:5,ic.inf,pch=95,col="blue")
points(1:5,ic.sup,pch=95,col="blue")
axis(1,seq(1:5),c("Unitat 1", "Unitat 2", "Unitat SM", "Unitat
Mèdica", "Unitat Quirúrgica"))
abline(h=0,col="red")
for (i in 1:5){
  lines(c(i,i),c(ic.inf[i],ic.sup[i]),col="blue")
}
box("outer",lwd=5)

```

## Té algun efecte aleatòri les mesures en els hospitals dins les unitats?

```

Datos<-data.frame(hospital=hospital,unidad=unidad,obs=esp,
explicativa=explicativa,temps=temps,programa,implantacio,any,valoracio
,difusio,tipus,temps2,explicativa2,unidad2,unidad3,unidad4)

```

```

formula = obs~
f(unidad,model="iid")+f(unidad3,model="iid")+f(unidad4,explicativa2,mo
del="iid")+
explicativa+implantacio+temps
resultat1 = inla(formula, family="poisson", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
), data=Datos,E=esp)

```

```
summary(resultat1)
```

```

resultat1$dic$dic
-mean(log(resultat1$cpo),na.rm=T)
-mean(log(resultat1$cpo[resultat1$cpo>0]),na.rm=T)

```



```

## Model 5: Taxa caigudes vs Percentatge de compliment mesures
individuals. Efectes mixtes. Unitat dins d'hospital.

mesura1<-Alteradopercent_mean*as.numeric(Quinzena)
mesura2<-Neuropercent_mean*as.numeric(Quinzena)
mesura3<-Contpercent_mean*as.numeric(Quinzena)
mesura4<-Medicpercent_mean*as.numeric(Quinzena)
mesura5<-Percent_prof_mean*as.numeric(Quinzena)
mesura6<-CamaBaja_mean*as.numeric(Quinzena)
mesura7<-PacienteRiesgo_mean*as.numeric(Quinzena)
mesura8<-PacienteInfo_mean*as.numeric(Quinzena)
mesura9<-RecomLadoFuerte_mean*as.numeric(Quinzena)

Datos<-
data.frame(Datos,mesura1,mesura2,mesura3,mesura4,mesura5,mesura6,mesura7,mesura8,mesura9)

formula = obs~ f(hospital,model="iid")+f(unidad3,model="iid")+
mesura6+implantacio+temps+outlier

formula = obs~ f(hospital,model="iid")+f(unidad3,model="iid")+
mesura1+mesura4+mesura5+mesura8+implantacio+temps+outlier

formula = obs~ f(hospital,model="iid")+f(unidad3,model="iid")+
mesura1+mesura2+mesura3+mesura4+implantacio+temps+outlier

formula = obs~ f(hospital,model="iid")+f(unidad3,model="iid")+
mesura5+mesura6+mesura8+mesura9+implantacio+temps+outlier

resultat1 = inla(formula, family="poisson", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
), data=Datos,E=esp)

summary(resultat1)

resultat1$dic$dic
-mean(log(resultat1$cpo),na.rm=T)
-mean(log(resultat1$cpo[resultat1$cpo>0]),na.rm=T)

par(mfrow=c(3,1))
plot(resultat1$marginals.fixed$"mesura6"[,1],resultat1$marginals.fixed
$"mesura6"[,2],xlab="",ylab="",main="Efecte Llit baix")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"temps"[,1],resultat1$marginals.fixed$"
temps"[,2],xlab="",ylab="",main="Efecte Quinzena")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"implantacio"[,1],resultat1$marginals.f
ixed$"implantacio"[,2],xlab="",ylab="",main="Efecte Implantació")
abline(v=0,col="red")
box("outer",lwd=5)

par(mfrow=c(3,3))

```

```

plot(resultat1$marginals.fixed$"mesura1"[,1],resultat1$marginals.fixed
$"mesura1"[,2],xlab="",ylab="",main="Efecte Estat cognitiu alterat
HC")
abline(v=0,col="red")
#plot(resultat1$marginals.fixed$"mesura2"[,1],resultat1$marginals.fixe
d$"mesura2"[,2],xlab="",ylab="",main="Efecte Malaltia neuro HC")
#abline(v=0,col="red")
#plot(resultat1$marginals.fixed$"mesura3"[,1],resultat1$marginals.fixe
d$"mesura3"[,2],xlab="",ylab="",main="Efecte Problemes continència
HC")
#abline(v=0,col="red")
plot(resultat1$marginals.fixed$"mesura4"[,1],resultat1$marginals.fixed
$"mesura4"[,2],xlab="",ylab="",main="Efecte Medicació Risc HC")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"mesura5"[,1],resultat1$marginals.fixed
$"mesura5"[,2],xlab="",ylab="",main="Efecte Professionals")
abline(v=0,col="red")
#plot(resultat1$marginals.fixed$"mesura6"[,1],resultat1$marginals.fixe
d$"mesura6"[,2],xlab="",ylab="",main="Efecte Llit baix")
#abline(v=0,col="red")
#plot(resultat1$marginals.fixed$"mesura7"[,1],resultat1$marginals.fixe
d$"mesura7"[,2],xlab="",ylab="",main="Efecte Pacient Risc HC")
#abline(v=0,col="red")
plot(resultat1$marginals.fixed$"mesura8"[,1],resultat1$marginals.fixed
$"mesura8"[,2],xlab="",ylab="",main="Efecte Informació Família")
abline(v=0,col="red")
#plot(resultat1$marginals.fixed$"mesura9"[,1],resultat1$marginals.fixe
d$"mesura9"[,2],xlab="",ylab="",main="Efecte Recomanar Costat")
#abline(v=0,col="red")
box("outer",lwd=5)

```

```

par(mfrow=c(2,2))
plot(resultat1$marginals.fixed$"mesura1"[,1],resultat1$marginals.fixed
$"mesura1"[,2],xlab="",ylab="",main="Efecte Estat cognitiu alterat
HC")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"mesura2"[,1],resultat1$marginals.fixed
$"mesura2"[,2],xlab="",ylab="",main="Efecte Malaltia neuro HC")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"mesura3"[,1],resultat1$marginals.fixed
$"mesura3"[,2],xlab="",ylab="",main="Efecte Problemes continència HC")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"mesura4"[,1],resultat1$marginals.fixed
$"mesura4"[,2],xlab="",ylab="",main="Efecte Medicació Risc HC")
abline(v=0,col="red")
box("outer",lwd=5)

```

```

par(mfrow=c(2,2))
plot(resultat1$marginals.fixed$"mesura5"[,1],resultat1$marginals.fixed
$"mesura5"[,2],xlab="",ylab="",main="Efecte Professionals")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"mesura6"[,1],resultat1$marginals.fixed
$"mesura6"[,2],xlab="",ylab="",main="Efecte Llit baix")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"mesura8"[,1],resultat1$marginals.fixed
$"mesura8"[,2],xlab="",ylab="",main="Efecte Informació Família")
abline(v=0,col="red")

```

```
plot(resultat1$marginals.fixed$"mesura9"[,1],resultat1$marginals.fixed
$"mesura9"[,2],xlab="",ylab="",main="Efecte Recomanar Costat")
abline(v=0,col="red")
box("outer",lwd=5)
```

### Anem a veure quin és l'efecte de cada hospital.

```
resultat1$marginals.random
resultat1$marginals.random$hospital[names(resultat1$marginals.random$h
ospital)[i]] # La distribució marginal de l'hospital i per les mesures
```

# Generem una mostra aleatoria de l'efecte aleatori de les mesures per cada hospital

```
efecte.h1 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[1]][[1]])
efecte.h2 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[2]][[1]])
efecte.h3 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[3]][[1]])
efecte.h4 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[4]][[1]])
efecte.h5 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[5]][[1]])
efecte.h6 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[6]][[1]])
efecte.h7 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[7]][[1]])
efecte.h8 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[8]][[1]])
efecte.h9 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[9]][[1]])
efecte.h10 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[10]][[1]])
efecte.h11 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[11]][[1]])
efecte.h12 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[12]][[1]])
efecte.h13 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[13]][[1]])
efecte.h14 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[14]][[1]])
efecte.h15 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[15]][[1]])
```



```

efecte.h36 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[36]][[1]])
efecte.h37 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[37]][[1]])
efecte.h38 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[38]][[1]])
efecte.h39 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[39]][[1]])
efecte.h40 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[40]][[1]])
efecte.h41 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[41]][[1]])
efecte.h42 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[42]][[1]])
efecte.h43 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[43]][[1]])
efecte.h44 =
inla.rmarginal(1000,resultat1$marginals.random$hospital[names(resultat
1$marginals.random$hospital)[44]][[1]])

```

```

mitjana<-
c(mean(efecte.h1),mean(efecte.h2),mean(efecte.h3),mean(efecte.h4),mean
(efecte.h5),mean(efecte.h6),mean(efecte.h7),mean(efecte.h8),
mean(efecte.h9),mean(efecte.h10),mean(efecte.h11),mean(efecte.h12),mea
n(efecte.h13),mean(efecte.h14),mean(efecte.h15),mean(efecte.h16),
mean(efecte.h17),mean(efecte.h18),mean(efecte.h19),mean(efecte.h20),me
an(efecte.h21),mean(efecte.h22),mean(efecte.h23),mean(efecte.h24),mean
(efecte.h25),
mean(efecte.h26),mean(efecte.h27),mean(efecte.h28),mean(efecte.h29),me
an(efecte.h30),mean(efecte.h31),mean(efecte.h32),mean(efecte.h33),mean
(efecte.h34),
mean(efecte.h35),mean(efecte.h36),mean(efecte.h37),mean(efecte.h38),me
an(efecte.h39),mean(efecte.h40),mean(efecte.h41),mean(efecte.h42),mean
(efecte.h43),
mean(efecte.h44))

```

```

ic.inf<-
c(quantile(efecte.h1,0.025),quantile(efecte.h2,0.025),quantile(efecte.
h3,0.025),quantile(efecte.h4,0.025),quantile(efecte.h5,0.025),quantile
(efecte.h6,0.025),quantile(efecte.h7,0.025),quantile(efecte.h8,0.025),
quantile(efecte.h9,0.025),quantile(efecte.h10,0.025),quantile(efecte.h
11,0.025),quantile(efecte.h12,0.025),quantile(efecte.h13,0.025),quanti
le(efecte.h14,0.025),quantile(efecte.h15,0.025),quantile(efecte.h16,0.
025),
quantile(efecte.h17,0.025),quantile(efecte.h18,0.025),quantile(efecte.
h19,0.025),quantile(efecte.h20,0.025),quantile(efecte.h21,0.025),quant
ile(efecte.h22,0.025),quantile(efecte.h23,0.025),quantile(efecte.h24,0
.025),quantile(efecte.h25,0.025),
quantile(efecte.h26,0.025),quantile(efecte.h27,0.025),quantile(efecte.
h28,0.025),quantile(efecte.h29,0.025),quantile(efecte.h30,0.025),quant
ile(efecte.h31,0.025),quantile(efecte.h32,0.025),quantile(efecte.h33,0
.025),quantile(efecte.h34,0.025),

```

```
quantile(efecte.h35,0.025),quantile(efecte.h36,0.025),quantile(efecte.
h37,0.025),quantile(efecte.h38,0.025),quantile(efecte.h39,0.025),quant
ile(efecte.h40,0.025),quantile(efecte.h41,0.025),quantile(efecte.h42,0
.025),quantile(efecte.h43,0.025),
quantile(efecte.h44,0.025))
```

```
ic.sup<-
c(quantile(efecte.h1,0.975),quantile(efecte.h2,0.975),quantile(efecte.
h3,0.975),quantile(efecte.h4,0.975),quantile(efecte.h5,0.975),quantile
(efecte.h6,0.975),quantile(efecte.h7,0.975),quantile(efecte.h8,0.975),
quantile(efecte.h9,0.975),quantile(efecte.h10,0.975),quantile(efecte.h
11,0.975),quantile(efecte.h12,0.975),quantile(efecte.h13,0.975),quanti
le(efecte.h14,0.975),quantile(efecte.h15,0.975),quantile(efecte.h16,0.
975),
quantile(efecte.h17,0.975),quantile(efecte.h18,0.975),quantile(efecte.
h19,0.975),quantile(efecte.h20,0.975),quantile(efecte.h21,0.975),quant
ile(efecte.h22,0.975),quantile(efecte.h23,0.975),quantile(efecte.h24,0
.975),quantile(efecte.h25,0.975),
quantile(efecte.h26,0.975),quantile(efecte.h27,0.975),quantile(efecte.
h28,0.975),quantile(efecte.h29,0.975),quantile(efecte.h30,0.975),quant
ile(efecte.h31,0.975),quantile(efecte.h32,0.975),quantile(efecte.h33,0
.975),quantile(efecte.h34,0.975),
quantile(efecte.h35,0.975),quantile(efecte.h36,0.975),quantile(efecte.
h37,0.975),quantile(efecte.h38,0.975),quantile(efecte.h39,0.975),quant
ile(efecte.h40,0.975),quantile(efecte.h41,0.975),quantile(efecte.h42,0
.975),quantile(efecte.h43,0.975),
quantile(efecte.h44,0.975))
```

```
#par(mfrow=c(2,1))
plot(1:44,mitjana,ylim=c(min(ic.inf),max(ic.sup)),xlim=c(0.95,44.05),p
ch=19,main="Efecte dels hospitals",xlab="Hospitals",ylab="")
points(1:44,ic.inf,pch=95,col="blue")
points(1:44,ic.sup,pch=95,col="blue")
#axis(1,seq(1:44),cex.axis=.5)
abline(h=0,col="red")
for (i in 1:44){
  lines(c(i,i),c(ic.inf[i],ic.sup[i]),col="blue")
}
box("outer",lwd=10)
```

```
## Té algun efecte aleatòri les mesures en els hospitals?
formula = obs~
f(hospital,model="iid")+f(unidad3,model="iid")+f(unidad4,explicativa2,
model="iid")+
explicativa+implantacio+temps+outlier
resultat1 = inla(formula, family="poisson", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
), data=Datos,E=esp)
```

```
summary(resultat1)
```

```
resultat1$dic$dic
-mean(log(resultat1$cpo),na.rm=T)
-mean(log(resultat1$cpo[resultat1$cpo>0]),na.rm=T)
```

```
##### VALIDACIÓ DEL MODEL
```

```

# Taxes de caigudes
RR<-resultat1$summary.fitted.values$mean*1000

res<-abs(tanpermil-RR)
res.ok<-rep(NA,length(res))
res.ok[which(abs(res)<2)]<-1
res.ok[which(abs(res)>2)]<-0

par(mfrow=c(1,2))
boxplot(res,main="Taxa de caigudes estimada")
boxplot(tanpermil,main="Taxa de caigudes observada")
box("outer",lwd=10)

##### Mesures Individuals

formula = obs~ f(hospital,model="iid")+f(unidad3,model="iid")+
sabates+llit+registre+habitacio+timbre+lavabo+terra+pacientrisc+info+
implantacio+temps+outlier
resultat1 = inla(formula, family="poisson", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
), data=Datos,E=esp)

summary(resultat1)

resultat1$dic$dic
-mean(log(resultat1$cpo),na.rm=T)
-mean(log(resultat1$cpo[resultat1$cpo>0]),na.rm=T)

par(mfrow=c(3,1))
plot(resultat1$marginals.fixed$"explicativa"[,1],resultat1$marginals.f
ixed$"explicativa"[,2],xlab="",ylab="",main="Efecte Mesures")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"temps"[,1],resultat1$marginals.fixed$"
temps"[,2],xlab="",ylab="",main="Efecte Quinzena")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"implantacio"[,1],resultat1$marginals.f
ixed$"implantacio"[,2],xlab="",ylab="",main="Efecte Implantació")
abline(v=0,col="red")
box("outer",lwd=5)

```

```

## Model 3.1: Taxa caigudes vs Mesures Individuals. Efectes mixtes.
Unitat dins d'hospital.
formula = obs~ f(hospital,model="iid")+f(unidad3,model="iid")+
MPacient+MProfessionals+MOrganitzacio+implantacio+temps+outlier

formula = obs~ f(hospital,model="iid")+f(unidad3,model="iid")+
MOrganitzacio+MPacient+implantacio+temps+outlier

resultat1 = inla(formula, family="poisson", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
), data=Datos,E=esp)

summary(resultat1)

resultat1$dic$dic
-mean(log(resultat1$cpo),na.rm=T)
-mean(log(resultat1$cpo[resultat1$cpo>0]),na.rm=T)

par(mfrow=c(2,1))
plot(resultat1$marginals.fixed$"MPacient"[,1],resultat1$marginals.fixed$
"MPacient"[,2],xlab="",ylab="",main="Efecte Mesures de Pacients")
abline(v=0,col="red")
#plot(resultat1$marginals.fixed$"MProfessionals"[,1],resultat1$marginal
s.fixed$"MProfessionals"[,2],xlab="",ylab="",main="Efecte Mesures de
Professionals")
#abline(v=0,col="red")
plot(resultat1$marginals.fixed$"MOrganitzacio"[,1],resultat1$marginals
.fixed$"MOrganitzacio"[,2],xlab="",ylab="",main="Efecte Mesures de
Organització")
abline(v=0,col="red")
box("outer",lwd=5)

#### Individualment
formula = obs~ f(hospital,model="iid")+f(unidad3,model="iid")+
MPacient+implantacio+temps+outlier
resultat1 = inla(formula, family="poisson", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
), data=Datos,E=esp)

summary(resultat1)

resultat1$dic$dic
-mean(log(resultat1$cpo),na.rm=T)
-mean(log(resultat1$cpo[resultat1$cpo>0]),na.rm=T)

par(mfrow=c(3,1))
plot(resultat1$marginals.fixed$"MPacient"[,1],resultat1$marginals.fixed$
"MPacient"[,2],xlab="",ylab="",main="Efecte Mesures de Pacient")
abline(v=0,col="red")

formula = obs~ f(hospital,model="iid")+f(unidad3,model="iid")+

```



```

MProfessionals+implantacio+temps+outlier
resultat1 = inla(formula, family="poisson", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
), data=Datos,E=esp)

summary(resultat1)

resultat1$dic$dic
-mean(log(resultat1$cpo),na.rm=T)
-mean(log(resultat1$cpo[resultat1$cpo>0]),na.rm=T)

plot(resultat1$marginals.fixed$"MProfessionals"[,1],resultat1$marginal
s.fixed$"MProfessionals"[,2],xlab="",ylab="",main="Efecte Mesures de
Professionals")
abline(v=0,col="red")

formula = obs~ f(hospital,model="iid")+f(unidad3,model="iid")+
MOrganitzacio+implantacio+temps+outlier
resultat1 = inla(formula, family="poisson", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
), data=Datos,E=esp)

summary(resultat1)

resultat1$dic$dic
-mean(log(resultat1$cpo),na.rm=T)
-mean(log(resultat1$cpo[resultat1$cpo>0]),na.rm=T)

plot(resultat1$marginals.fixed$"MOrganitzacio"[,1],resultat1$marginals
.fixed$"MOrganitzacio"[,2],xlab="",ylab="",main="Efecte Mesures de
Organització")
abline(v=0,col="red")
box("outer",lwd=5)

#### De les mesures de professional, quina afecta més.

# Llit
formula = obs~ f(hospital,model="iid")+f(unidad3,model="iid")+
llit+implantacio+temps+outlier
resultat1 = inla(formula, family="poisson", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
), data=Datos,E=esp)

resultat1$dic$dic
-mean(log(resultat1$cpo),na.rm=T)
-mean(log(resultat1$cpo[resultat1$cpo>0]),na.rm=T)

par(mfrow=c(2,3))
plot(resultat1$marginals.fixed$"llit"[,1],resultat1$marginals.fixed$"l
lit"[,2],xlab="",ylab="",main="Efecte Mesura Llit")
abline(v=0,col="red")
box("outer",lwd=5)

```

```

# Registre
formula = obs~ f(hospital,model="iid")+f(unidad3,model="iid")+
registre+implantacio+temps+outlier
resultat1 = inla(formula, family="poisson", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
), data=Datos,E=esp)

resultat1$dic$dic
-mean(log(resultat1$cpo),na.rm=T)
-mean(log(resultat1$cpo[resultat1$cpo>0]),na.rm=T)

plot(resultat1$marginals.fixed$"registre"[,1],resultat1$marginals.fixed$
"d$registre"[,2],xlab="",ylab="",main="Efecte Mesura Registre")
abline(v=0,col="red")

# Timbre
formula = obs~ f(hospital,model="iid")+f(unidad3,model="iid")+
timbre+implantacio+temps+outlier
resultat1 = inla(formula, family="poisson", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
), data=Datos,E=esp)

resultat1$dic$dic
-mean(log(resultat1$cpo),na.rm=T)
-mean(log(resultat1$cpo[resultat1$cpo>0]),na.rm=T)

plot(resultat1$marginals.fixed$"timbre"[,1],resultat1$marginals.fixed$
"timbre"[,2],xlab="",ylab="",main="Efecte Mesura Timbre")
abline(v=0,col="red")

# Pacient Risc
formula = obs~ f(hospital,model="iid")+f(unidad3,model="iid")+
pacientrisc+implantacio+temps+outlier
resultat1 = inla(formula, family="poisson", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
), data=Datos,E=esp)

resultat1$dic$dic
-mean(log(resultat1$cpo),na.rm=T)
-mean(log(resultat1$cpo[resultat1$cpo>0]),na.rm=T)

plot(resultat1$marginals.fixed$"pacientrisc"[,1],resultat1$marginals.f
ixed$"pacientrisc"[,2],xlab="",ylab="",main="Efecte Mesura Pacient
Risc")
abline(v=0,col="red")

# Informació Família
formula = obs~ f(hospital,model="iid")+f(unidad3,model="iid")+
info+implantacio+temps+outlier
resultat1 = inla(formula, family="poisson", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
), data=Datos,E=esp)

resultat1$dic$dic
-mean(log(resultat1$cpo),na.rm=T)
-mean(log(resultat1$cpo[resultat1$cpo>0]),na.rm=T)

```

```
plot(resultat1$marginals.fixed$"info"[,1],resultat1$marginals.fixed$"i
nfo"[,2],xlab="",ylab="",main="Efecte Mesura Informació")
abline(v=0,col="red")
```

```
formula = obs~ f(hospital,model="iid")+f(unidad3,model="iid")+
timbre+pacientrisc+info+implantacio+temps+outlier
```

```
resultat1 = inla(formula, family="poisson", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
), data=Datos,E=esp)
```

```
summary(resultat1)
```

```
resultat1$dic$dic
-mean(log(resultat1$cpo),na.rm=T)
-mean(log(resultat1$cpo[resultat1$cpo>0]),na.rm=T)
```

```
par(mfrow=c(3,1))
#plot(resultat1$marginals.fixed$"llit"[,1],resultat1$marginals.fixed$
llit"[,2],xlab="",ylab="",main="Efecte Mesura Llit")
#abline(v=0,col="red")
plot(resultat1$marginals.fixed$"timbre"[,1],resultat1$marginals.fixed$
"timbre"[,2],xlab="",ylab="",main="Efecte Mesura Timbre")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"info"[,1],resultat1$marginals.fixed$"i
nfo"[,2],xlab="",ylab="",main="Efecte Mesura Informació")
abline(v=0,col="red")
#plot(resultat1$marginals.fixed$"registre"[,1],resultat1$marginals.fix
ed$"registre"[,2],xlab="",ylab="",main="Efecte Mesura Registre")
#abline(v=0,col="red")
plot(resultat1$marginals.fixed$"pacientrisc"[,1],resultat1$marginals.f
ixed$"pacientrisc"[,2],xlab="",ylab="",main="Efecte Mesura Pacient
Risc")
abline(v=0,col="red")
box("outer",lwd=5)
```

```
#### De les mesures d'organització, quina afecta més.
```

```
# Habitació
formula = obs~ f(hospital,model="iid")+f(unidad3,model="iid")+
habitacio+implantacio+temps+outlier
resultat1 = inla(formula, family="poisson", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
), data=Datos,E=esp)
```

```
resultat1$dic$dic
-mean(log(resultat1$cpo),na.rm=T)
-mean(log(resultat1$cpo[resultat1$cpo>0]),na.rm=T)
```

```
par(mfrow=c(3,1))
```

```

plot(resultat1$marginals.fixed$"habitacio"[,1],resultat1$marginals.fixed$
"habitacio"[,2],xlab="",ylab="",main="Efecte Mesura Habitació")
abline(v=0,col="red")
box("outer",lwd=5)

# Lavabo
formula = obs~ f(hospital,model="iid")+f(unidad3,model="iid")+
lavabo+implantacio+temps+outlier
resultat1 = inla(formula, family="poisson", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
), data=Datos,E=esp)

resultat1$dic$dic
-mean(log(resultat1$cpo),na.rm=T)
-mean(log(resultat1$cpo[resultat1$cpo>0]),na.rm=T)

plot(resultat1$marginals.fixed$"lavabo"[,1],resultat1$marginals.fixed$
"lavabo"[,2],xlab="",ylab="",main="Efecte Mesura Lavabo")
abline(v=0,col="red")

# Terra
formula = obs~ f(hospital,model="iid")+f(unidad3,model="iid")+
terra+implantacio+temps+outlier
resultat1 = inla(formula, family="poisson", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
), data=Datos,E=esp)

resultat1$dic$dic
-mean(log(resultat1$cpo),na.rm=T)
-mean(log(resultat1$cpo[resultat1$cpo>0]),na.rm=T)

plot(resultat1$marginals.fixed$"terra"[,1],resultat1$marginals.fixed$
"terra"[,2],xlab="",ylab="",main="Efecte Mesura Terra")
abline(v=0,col="red")

formula = obs~ f(hospital,model="iid")+f(unidad3,model="iid")+
lavabo+terra+habitacio+implantacio+temps+outlier
resultat1 = inla(formula, family="poisson", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
), data=Datos,E=esp)

resultat1$dic$dic
-mean(log(resultat1$cpo),na.rm=T)
-mean(log(resultat1$cpo[resultat1$cpo>0]),na.rm=T)

par(mfrow=c(3,1))
plot(resultat1$marginals.fixed$"habitacio"[,1],resultat1$marginals.fixed$
"habitacio"[,2],xlab="",ylab="",main="Efecte Mesura Habitació")
abline(v=0,col="red")
plot(resultat1$marginals.fixed$"lavabo"[,1],resultat1$marginals.fixed$
"lavabo"[,2],xlab="",ylab="",main="Efecte Mesura Lavabo")
abline(v=0,col="red")

```

```
plot(resultat1$marginals.fixed$"terra"[,1],resultat1$marginals.fixed$"
terra"[,2],xlab="",ylab="",main="Efecte Mesura Terra")
abline(v=0,col="red")
box("outer",lwd=5)
```

```
###Mesures organització i professionals
```

```
formula = obs~ f(hospital,model="iid")+f(unidad3,model="iid")+
lavabo+llit+implantacio+temps+outlier
resultat1 = inla(formula, family="poisson", control.compute =
list(dic=T,cpo=TRUE),control.predictor=list(compute=TRUE,cdf=c(log(1))
), data=Datos,E=esp)
```

```
resultat1$dic$dic
-mean(log(resultat1$cpo),na.rm=T)
-mean(log(resultat1$cpo[resultat1$cpo>0]),na.rm=T)
```

```
par(mfrow=c(2,1))
plot(resultat1$marginals.fixed$"llit"[,1],resultat1$marginals.fixed$"l
lit"[,2],xlab="",ylab="",main="Efecte Mesura LLit")
abline(v=0,col="red")
#plot(resultat1$marginals.fixed$"timbre"[,1],resultat1$marginals.fixed
$"timbre"[,2],xlab="",ylab="",main="Efecte Mesura Timbre")
#abline(v=0,col="red")
plot(resultat1$marginals.fixed$"lavabo"[,1],resultat1$marginals.fixed$
"lavabo"[,2],xlab="",ylab="",main="Efecte Mesura Lavabo")
abline(v=0,col="red")
box("outer",lwd=5)
```